



**İMPUTASYON YÖNTEMLERİNİN DERİN
ÖĞRENME MODELLERİNİN PERFORMANSI
ÜZERİNDEKİ ETKİSİNİN İNCELENMESİ**

Yüksek Lisans Tezi

Kürşat ATMACA

Eskişehir 2024

**İMPUTASYON YÖNTEMLERİNİN DERİN ÖĞRENME MODELLERİNİN
PERFORMANSI ÜZERİNDEKİ ETKİSİNİN İNCELENMESİ**

Kürşat ATMACA

Yüksek Lisans Tezi

İstatistik Anabilim Dalı

İstatistik Teorisi Bilim Dalı

Danışman: Dr. Öğr. Üyesi İsmail YENİLMEZ

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Haziran 2024

JÜRİ VE ENSTİTÜ ONAYI

Kürşat ATMACA'nın İMPUTASYON YÖNTEMLERİNİN DERİN ÖĞRENME MODELLERİNİN PERFORMANSI ÜZERİNDEKİ ETKİSİNİN İNCELENMESİ başlıklı çalışması 11/06/2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, İstatistik Anabilim dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Dr. Öğr. Üyesi İsmail YENİLMEZ

Üye

: Prof. Dr. Yeliz MERT KANTAR

Üye

: Prof. Dr. Arzu ALTIN YAVUZ

Prof. Dr. Semra KURAMA

Lisansüstü Eğitim Enstitüsü Müdürü

11/06/2024

DANIřMAN ONAYI

Daniřmanlıđını yrttđm Yksek Lisans đrencisi Krřat ATMACA, İMPUTASYON YNTEMLERİNİN DERİN đRENME MODELLERİNİN PERFORMANSI ZERİNDEKİ ETKİSİNİN İNCELENMESİ bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduđu tez tarafımca incelenmiř ve đrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı

Dr. đr. yesi İsmail YENİLMEZ

ÖZET

İMPUTASYON YÖNTEMLERİNİN DERİN ÖĞRENME MODELLERİNİN PERFORMANSI ÜZERİNDEKİ ETKİSİNİN İNCELENMESİ

Kürşat ATMACA

İstatistik Anabilim Dalı

İstatistik Teorisi Bilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Haziran 2024

Danışman: Dr. Öğr. Üyesi İsmail YENİLMEZ

Bu tez çalışmasında, Türk Hava Yolları, Lufthansa Hava Yolları, Delta Hava Yolları hisse fiyatları ve simülasyon yardımıyla sentetik veri setleri kullanılarak zaman serisi analizinde imputasyon yöntemlerinin kayıp verileri doldurma performansı ve derin öğrenme yöntemlerinin tahmin performansı incelenmiştir. Çalışmada LSTM, GRU, RNN ve Transformer modelleri kullanılarak analizler yapılmıştır. Veri setlerinde %5, %15 ve %25 oranında eksik veri oluşturulmuş ve bu eksik veriler lineer, spline, Stineman, ortalama ve rasgele imputasyon teknikleriyle doldurulmuştur.

Elde edilen sonuçlar, her bir modelin performansının, kullanılan imputasyon tekniğine ve eksik veri oranına bağlı olarak değiştiğini göstermektedir. Özellikle derin öğrenme yöntemlerinin, eksik veri oranı arttıkça ve kullanılan imputasyon tekniğine bağlı olarak performanslarının farklılaştığı gözlemlenmiştir. Analiz yöntemlerinden Transformer modeli, genellikle diğer modellere göre daha iyi performans sergilemiş; imputasyon yöntemlerinden Stineman imputasyon tekniği ani değişimler ve keskin dönüşlerin bulunduğu veri setlerinde daha başarılı sonuçlar vermiş ve Spline imputasyon tekniği ise doğrusal olmayan ilişkilerde üstün sonuçlar elde edilmesini sağlamıştır.

Zaman serisi analizlerinde imputasyon yöntemlerinin ve derin öğrenme yöntemlerinin performansları böylece karşılaştırmalı ve kombinasyonlu incelenmiştir. Model performanslarını iyileştirmek için hangi yöntem ve yöntem çiftlerinin uygun olabileceği konusunda önemli bulgular sunulmuştur.

Anahtar Sözcükler: Zaman serisi analizi, Kayıp veri, İmputasyon, Derin öğrenme modelleri, Simülasyon, Performans karşılaştırma.

ABSTRACT

AN EXAMINATION OF THE IMPACT OF IMPUTATION METHODS ON THE PERFORMANCE OF DEEP LEARNING MODELS

Kürşat ATMACA

Department of Statistics

Programme in Statistics Theory

Eskişehir Technical University, Institute of Graduate Programs, June 2024

Supervisor: Asst. Prof. Dr. İsmail YENİLMEZ

In this thesis study, the performance of imputation methods in filling missing data and the estimation performance of deep learning methods in time series analysis were examined using Turkish Airlines, Lufthansa Airlines, Delta Airlines stock prices and synthetic dataset based on simulation. In the study, analyzes were conducted using LSTM, GRU, RNN and Transformer models. Missing data was generated at the rate of 5%, 15% and 25% in the dataset, and these missing data were filled with linear, spline, Stineman, average and random imputation techniques.

The results obtained show that the performance of each model varies depending on the imputation technique used and the rate of missing data. It has been observed that the performance of deep learning methods, in particular, varies as the rate of missing data increases and depending on the imputation technique used. Among the analysis methods, the Transformer model generally performed better than other models; Among the imputation methods, the Stineman imputation technique performed well for dataset with sudden changes and sharp turns, and the Spline imputation technique provided superior results in non-linear relationships.

The performances of imputation methods and deep learning methods in time series analyzes were examined comparatively and in combination. Important findings are presented regarding which methods and pairs of methods may be suitable to improve model performances.

Keywords: Time series analysis, Missing data, Imputation, Deep learning models, Simulation, Performance comparison.

TEŞEKKÜR

Eğitim hayatım süresince her zaman yanımda olup bana yardım eden ve manevi desteğini hiçbir zaman esirgemeyen başta değerli aileme ve ablama teşekkür ederim.

Çalışmamın her aşamasında yardımcı olan tez danışmanım Dr. Öğr. Üyesi İsmail YENİLMEZ'e teşekkürlerimi sunarım.

Bu çalışmayı sevgili aileme ve ablama ithaf ediyorum.

Kürşat ATMACA



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Kürşat ATMACA

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER.....	VIII
TABLolar DİZİNİ.....	XI
ŞEKİLLER DİZİNİ.....	XII
GÖRSELLER DİZİNİ	XIII
SİMGELER VE KISALTMALAR DİZİNİ.....	XIV
1. GİRİŞ.....	1
1.1. Literatür Taraması	4
2. FİNANSAL PİYASALAR, İSTATİSTİKSEL ANALİZ VE EKSİK VERİ	10
2.1. Finansal Sistem ve Finansal Piyasa Kavramı.....	10
2.2. Hisse Senetleri Değerlemesinde Kullanılan Yöntemler	11
2.2.1. Temel analiz ve hisse senedi değerlendirme	11
2.2.2. Teknik analiz ve hisse senedi değerlendirme	11
2.2.3. Grafik analizi ve trendlerin incelenmesi	13
2.3. Hisse Senedi Değerlemesinde Zaman Serisi Analizi	14
2.3.1. Zaman serisinde eksik veri	16
3. YÖNTEM	17
3.1. İmputasyon Teknikleri	17
3.1.1. Lineer imputasyon.....	17
3.1.2. Spline imputasyon	18

3.1.3. Stineman imputasyon.....	19
3.1.4. Ortalama imputasyon	20
3.1.5. Rasgele imputasyon.....	20
3.2. Zaman Serisi Analizinde Derin Öğrenme.....	21
3.2.1. Gözetimli öğrenme	22
3.2.2. Gözetimsiz öğrenme	22
3.2.3. Pekiştirmeli öğrenme	22
3.2.4. Aktivasyon fonksiyonu.....	23
3.2.5. Kayıp fonksiyonu.....	23
3.2.6. ADAM optimizasyonu.....	24
3.3. Yapay Sinir Ağları ve Çalışma Prensibi	24
3.4. Tekrarlayan Sinir Ağları (Recurrent Neural Networks)	25
3.4.1. Uzun vadeli bellek (Long short-term memory (LSTM))	27
3.4.2. Geçitli tekrarlayan birim (Gated recurrent unit (GRU)).....	29
3.5. Transformer Model.....	31
3.6. Çalışmada Kullanılan İstatistiksel Teknikler ve Seçim Kriterleri	34
3.6.1. Veri ölçeklendirme	34
3.6.2. Artık analizi(Residual analysis)	34
3.6.3. Augmented Dickey-Fuller(ADF) Testi	35
3.6.4. Ortalama mutlak hata yüzdesi (MAPE)	35
3.6.5. Kök ortalama kare hatası (RMSE).....	36
3.6.6. R-kare (R^2)	36
4. ANALİZ.....	37
4.1. Simülasyon.....	37
4.2. Uygulama	38
4.3. Zaman Serisi Veri Seti İçin Derin Öğrenme Modellerinin Mimarisi ve Parametreleri.....	39
4.4. Model Performans Karşılaştırmaları ve Yorum.....	40
4.4.1. Simulasyon ile sentetik veri uygulaması.....	40
4.4.2. THYAO hisse senedi için uygulama	46
4.4.3. LHA hisse senedi için uygulama	52
4.4.4. DAL hisse senedi için uygulama.....	58

5. SONUÇ 65

KAYNAKÇA..... 69

ÖZGEÇMİŞ



TABLÖLAR DİZİNİ

Sayfa

Tablo 4.1. Sentetik veri seti için tanımlayıcı istatistikler	40
Tablo 4.2. Sentetik veri seti için analiz sonuçları	41
Tablo 4.3. THYAO hisse senedi için tanımlayıcı istatistikler	46
Tablo 4.4 THYAO hisse senedi için analiz sonuçları	47
Tablo 4.5. LHA hisse senedi için tanımlayıcı istatistikler	52
Tablo 4.6. LHA hisse senedi için analiz sonuçları	53
Tablo 4.7. DAL hisse senedi için tanımlayıcı istatistikler	58
Tablo 4.8. DAL hisse senedi için analiz sonuçları	59

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1. Kavramlar ve yöntemlerin temsili ilişkisi	2
Şekil 2.1. Aktivasyon fonksiyonları	23
Şekil 2.2. RNN mimarisi	26
Şekil 2.3. LSTM mimarisi	28
Şekil 2.4. Geçitli tekrarlayan birim	31
Şekil 2.5. Transformer mimarisi	34



GÖRSELLER DİZİNİ

Sayfa

Görsel 4.1. Yapay hisse senedi RNN modellemesine ilişkin tahmin grafiği ...	42
Görsel 4.2. Yapay hisse senedi LSTM modellemesine ilişkin tahmin grafiği ..	43
Görsel 4.3. Yapay hisse senedi GRU modellemesine ilişkin tahmin grafiği ...	43
Görsel 4.4. Yapay hisse senedi Transformer modellemesine ilişkin tahmin grafiği	44
Görsel 4.5. Yapay hisse senedi %25 eksik veri ve Stineman imputasyon ile Transformer modellemesine ilişkin tahmin grafiği	45
Görsel 4.6. THYAO RNN modellemesine ilişkin tahmin grafiği	48
Görsel 4.7. THYAO LSTM modellemesine ilişkin tahmin grafiği	49
Görsel 4.8. THYAO GRU modellemesine ilişkin tahmin grafiği	49
Görsel 4.9. THYAO Transformer modellemesine ilişkin tahmin grafiği	50
Görsel 4.10. THYAO hisse senedi %25 eksik veri ve Spline imputasyon ile Transformer modellemesine ilişkin tahmin grafiği	51
Görsel 4.11. Lufthansa RNN modellemesine ilişkin tahmin grafiği	54
Görsel 4.12. Lufthansa LSTM modellemesine ilişkin tahmin grafiği	55
Görsel 4.13. Lufthansa GRU modellemesine ilişkin tahmin grafiği	55
Görsel 4.14. Lufthansa Transformer modellemesine ilişkin tahmin grafiği	56
Görsel 4.15. LHA hisse senedi %25 eksik veri ve Stineman imputasyon ile Transformer modellemesine ilişkin tahmin grafiği	57
Görsel 4.16. DAL LSTM modellemesine ilişkin tahmin grafiği	60
Görsel 4.17. DAL RNN modellemesine ilişkin tahmin grafiği	61
Görsel 4.18. DAL GRU modellemesine ilişkin tahmin grafiği	61
Görsel 4.19. DAL Transformer modellemesine ilişkin tahmin grafiği	62
Görsel 4.20. DAL hisse senedi %25 eksik veri ve Spline imputasyon ile Transformer modellemesine ilişkin tahmin grafiği	63

SİMGELER VE KISALTMALAR DİZİNİ

ADF : Augmented Dickey-Fuller

ANN : Artificial Neural Network (Yapay Sinir Ağları)

AR : Autoregressive (Oto regresif)

ARIMA : AutoRegressive Integrated Moving Average (Bütünleşik Oto regresif Hareketli Ortalama)

DAL : Delta Air Lines Stock Closing Prices (Delta Hava Yolları Hisse Senedi Kapanış Fiyatları)

DL : Deep Learning (Derin Öğrenme)

EMA : Exponential Moving Average (Üstel Hareketli Ortalama)

FNN : Feedforward Neural Network (İleri Beslemeli Sinir Ağı)

GANs : Generative Adversarial Networks (Çekişmeli Üretici Ağlar)

GARCH : Generalized Autoregressive Conditional Heteroskedasticity (Genelleştirilmiş Oto regresif Koşullu Değişen Varyans)

GRU : Gated Recurrent Unit (Geçitli Tekrarlayan Birim)

KT : Kareler Toplamı

LHA : Lufthansa Air Lines Stock Closing Prices (Lufthansa Hava Yolları Hisse Senedi Kapanış Fiyatları)

LSTM : Long Short-Term Memory (Uzun Kısa Süreli Bellek)

MACD : Moving Average Convergence Divergence (Hareketli Ortalama Yakınsama Ve Diverjans)

MAPE : Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hatası)

MA : Moving Average (Hareketli Ortalama)

ML : Machine Learning (Makine Öğrenmesi)

NLP : Natural Language Processing (Doğal Dil İşleme)

RMSE : Root Mean Square Error (Ortalama Karekök Sapması)

RNN : Recurrent Neural Network (Tekrarlayan Sinir Ağları)

RSI : Relative Strength Index (Görelî Güç Endeksi)

SMA : Simple Moving Average (Basit Hareketli Ortalama)

SGD : Stochastic Gradient Descent (Stokastik Gradyan İnişî)

SVM : Support Vector Machines (Destek Vektör Makineleri)

THYAO : Turkish Airlines Stock Closing Prices (Türk Hava Yolları Hisse Senedi Kapanış Fiyatları)

TM : Transformer Model

VAR : Vector Autoregression (Vektör Otoresresyon)


1. GİRİŞ

Finansal piyasalarda derin öğrenme algoritmalarının performansı, son yıllarda önemli bir araştırma konusu haline gelmiştir. Geleneksel finansal analiz yöntemlerine kıyasla, derin öğrenme algoritmaları daha karmaşık veri yapılarını ele alabilir ve doğruluk oranı daha yüksek tahminler yapabilir. Bu nedenle, finansal piyasalarda derin öğrenme tekniklerinin kullanımı, yatırımcılar, finansal analistler ve kurumlar arasında hızla yayılmaktadır (Farhad Morteza pour Shiri vd., 2023).

Finansal piyasalarda veri yapısı olarak sıklıkla zaman serisi ile çalışılmaktadır. Ancak hem kesit hem de zaman boyutunun var olduğu panel veri analizi de uygulanabilir. (Yenilmez ve Kantar, 2019). Zaman serisi herhangi bir olaya ilişkin gözlem değerlerinin zamana göre sıralanmasıyla oluşturulan dizilerdir ve özellikle finansal piyasalarda fiyat ve indeks gibi veriler zaman içinde bu diziyi oluşturur. Zaman serileri analizi ise, belirli zaman aralıklarında gözlenen bir olay hakkında, gözlenen serinin yapısını veren stokastik süreci modellemeyi ve geçmiş dönemlere ilişkin gözlem değerleri yardımıyla geleceğe yönelik tahminler yapmayı amaçlayan bir yöntemdir (Kaynar ve Taştan, 2010). Box-Jenkins yöntemi finansal alanda uygulanabilen zaman serileri analizinde kullanılan geleneksel yöntemlerden biridir (Çalık vd., 2022). Doğrusal ve durağan süreçlerde ya da durağan olmayan fakat çeşitli istatistiksel yöntemlerle durağanlaştırılabilen serilerde Box-Jenkins yöntemi başarıyla uygulanabilir (Kaynar ve Taştan, 2010). Ancak, bu tür modeller verilerin istatistiksel dağılımı ve durağanlığı hakkında birtakım varsayımlar gerektirmesinden dolayı doğrusal ve durağan olmayan finansal zaman serilerinin uzun vadeli tahminlerinde problemlere sahip oldukları görülmektedir (Kazem vd.,2013; Yu, vd., 2008; He vd., 2016; Niu vd., 2020).

Geleneksel yöntemlerin sınırlamalarıyla başa çıkmak ve daha doğru tahminler elde etmek amacıyla, yatırımcılar ve finansal kuruluşlar makine öğrenimi (Machine Learning - ML) yöntemlerine yönelmiştir. ML teknikleri, geleneksel yöntemlerin sahip olduğu sınırlamaların birçoğunu aşma potansiyeline sahiptir (Yenilmez ve Mugenzi, 2023; Mugenzi ve Yenilmez, 2023). Büyük veri setlerini işleyebilme, dinamik modeller oluşturabilme ve daha yüksek doğruluk sağlayabilme gibi avantajları sayesinde finansal piyasalarda daha etkin bir şekilde kullanılmaktadır (He vd., 2016). Ayrıca ML teknikleri ile karmaşık ilişkileri belirleme ve gelecekteki fiyat hareketlerini tahmin etme konularında büyük potansiyele sahiptir. Özellikle, Destek Vektör Makineleri (Support Vector Machines – SVM) , Rastgele Orman (Random Forest), Gradyan Arttırma

Makineleri (Gradient Boosting Machines), derin öğrenme (Deep Learning – DL) ve sinir ağları (Neural Network – NN) gibi makine öğrenimi algoritmaları, finansal piyasalarda yaygın olarak kullanılmakta olup volatilitiyi belirlemek ve gelecekteki fiyat hareketlerini tahmin etmede etkin bir yöntem olarak kullanılmaktadır (Ruder, 2016). Sinir ağları ve derin öğrenme yöntemlerinin geleneksel yöntemlere göre üstünlüklerinin olmasının yanı sıra hiper parametre belirleme gibi zorluklarının da bulunduğu gözardı edilmemelidir (Yenilmez ve Akçay, 2023).



Şekil 1.1. Kavramlar ve Yöntemlerin Temsili İlişkisi (Song vd., 2020)

ML yöntemleri bir bakıma genel bir çatıdır. Hatta bu çatı yapay zeka olarak genişletilebilir. Bu terimlerin bir alt kümesi ise derin öğrenme yaklaşımlarıdır. Bu süreç Şekil 1.1.'de temsil edilmektedir (Song vd., 2020). Makine öğrenmesinden derin öğrenmeye geçiş, veri işleme ve model oluşturma tekniklerinde büyük bir dönüşümü ifade eder. Makine öğrenimi, genellikle belirli özelliklerin seçilebildiği ve bu özelliklerin daha basit algoritmalarla işlenerek seçilebildiği bir süreçtir. Örneğin, lineer regresyon, lojistik regresyon, k-en yakın komşu ve karar ağaçları gibi algoritmalar, belirli bir problem için seçilen özellikler üzerinde çalışır. Bu yöntemler, sınırlı miktarda veri ile çalışmak ve iyi performans göstermek için uygundur (Goodfellow, 2016).

Derin öğrenme ise, veri işlemenin otomatikleştirildiği ve çok katmanlı sinir ağlarının kullanıldığı daha ileri bir yaklaşımdır. Bu yöntemler, büyük veri setleri üzerinde çalışarak daha karmaşık ve soyut temsiller öğrenebilir (Farhad Morteza Pour Shiri vd., 2023). Derin öğrenme modelleri, özellikle görüntü işleme, doğal dil işleme ve zaman serisi tahminleri gibi alanlarda üstün performans göstermektedir. Uzun Kısa Süreli Bellek

(Long Short-Term Memory - LSTM), Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) ve Transformer gibi modeller, derin öğrenmenin gücünü en iyi şekilde temsil eder. Bu modeller, veri içindeki karmaşık zaman bağımlılıklarını ve ilişkileri öğrenmede oldukça etkilidir ve geleneksel makine öğrenimi algoritmalarının ötesine geçerek daha doğru ve etkili tahminler yapabilirler. Bu geçiş, veri miktarındaki artış ve hesaplama gücündeki gelişmelerle desteklenmiş, makine öğrenimi ve yapay zeka araştırmalarında yeni bir dönemin kapılarını açmıştır. Derin öğrenme, büyük miktarda veriyi işleyerek ve bu verilerden anlamlı çıkarımlar yaparak, makinelerin daha önce mümkün olmayan görevleri gerçekleştirebilmesini sağlamıştır (Schmidhuber, 2016).

Derin öğrenme yöntemlerinin zaman serisi analizinde de kendine yer bularak geleneksel sayılabilecek yöntemlerle karşılaştırılması söz konusudur (Çalık vd, 2022; Yenilmez ve Mugenzi, 2023; Mugenzi ve Yenilmez, 2023). Ancak zaman serisi analizinde eksik veri sorunlarıyla sıkça karşılaşılır. Bu eksiklikler, veri toplama hatalarından, cihaz arızalarından veya kesintilerden kaynaklanabilir ve analizlerin doğruluğunu olumsuz etkileyebilir. Eksik verilerin uygun bir şekilde işlenmesi, yani imputasyon, veri setinin bütünlüğünü korur ve analizlerin güvenilirliğini artırır. İmputasyon yöntemleri, eksik veri noktalarını tahmin ederek veri setindeki trendlerin ve mevsimselliklerin bozulmasını önler (Yenilmez, 2024). Bu, zaman serisi analizinde daha tutarlı ve doğru sonuçlar elde edilmesini sağlar.

Bu çalışmanın amacı, eksik veri durumunda kullanılan imputasyon yöntemlerinin ve derin öğrenme yaklaşımlarını karşılaştırmaktır. Bir diğer önemli amaç ise bu karşılaştırmayı farklı seviyelerdeki eksik verilerin farklı imputasyon teknikleri ile tamamlanması senaryosu ile yapmaktır.

Çalışmanın yapısı şu şekildedir: İlk olarak bu bölümün devamında, zaman serisi analizindeki istatistiksel yöntemlerin, ML ve derin öğrenme yaklaşımlarının kullanımına dair literatür araştırması sunulmuştur. Ayrıca eksik veri durumunda kullanılan imputasyon tekniklerine dair literatür incelemesi ortaya konmuştur. Araştırmanın uygulama kısmına konu edilen havayolu şirketlerinin hisse senedi kapanış fiyatlarına dair araştırmalara da yer verilmiştir. Ek olarak analizde kullanılan veri setleri ile kullanılacak olan yöntemlerin ilişkisi paylaşılmıştır. İkinci bölümde, finansal piyasalara dair temel bilgiler ve analiz yöntemlerinden söz edilmiştir. Finansal piyasalarda yaygın kullanılan veri tipi olan zaman serisi verisi ile hisse senedi fiyat verileri ilişkisi açıklanmıştır. Zaman serisi verisinde sıklıkla karşılaşılan eksik veri problemine yer verilmiştir. Üçüncü bölüm

olan Yöntem başlığında çalışmada kullanılan zaman serisi analiz yöntemleri, eksik veri durumu için kullanılan imputasyon teknikleri ve istatistiksel karşılaştırma kriterleri sunulmuştur. Dördüncü bölüm olan Analiz başlığında simülasyon çalışması ve uygulama çalışmaları ortaya konulmuştur. Son bölüm olan Sonuç başlığında ise tüm bulgular paylaşılmış ve tartışılmıştır.

1.1. Literatür Taraması

Turan (2019) yaptığı çalışmada, çalışmada finansal varlıkların fiyatlarını tahmin etmek için derin öğrenme yöntemleri kullanılmış ve Borsa İstanbul 100 endeksinin 2001-2018 yılları arasındaki günlük kapanış değerleri kullanılarak analiz yapılmıştır. Araştırmada, tekrarlayan sinir ağı algoritmalarından LSTM ve GRU yöntemleri kullanılmıştır. Elde edilen sonuçlar üzerinden bu iki yöntem karşılaştırılmış ve GRU yönteminin daha başarılı tahmin sonuçları verdiği bulunmuştur.

Uzel (2018) ML ile ilgili yaptığı çalışmada, Türk Lirası'nın ABD Doları karşısındaki döviz kurunun değişim yönünü tahmin etmek için ML kullanılarak modeller geliştirilmiştir. Modellerin başarımı, FOREX piyasalarında yapılan alım-satım benzetimi ile gösterilmiştir. Elde edilen sonuçlar, geçmiş fiyat verileri kullanılarak gelecek fiyatların belirli bir ölçüde tahmin edilebileceğini göstermektedir. Bu da Türk Lirası kuru piyasasının Zayıf Formda Etkin Piyasa Hipotezi'nin tam olarak geçerli olmadığına işaret etmektedir.

Peştere (2021) çalışmada, firma derecelendirme literatüründeki eksikliği ele alarak, finansal oranlarla birlikte firma değerini değerlendirmeyi amaçlamıştır. Yapay sinir ağları (Artificial Neural Network -ANNs) yöntemi kullanılarak 12 çimento firmasının değerleri tespit edilmiş ve finansal oranlarla birlikte değerlendirilmiştir. ML yöntemleri kullanılarak yapılan analiz, finansal oranlar ve firma değerinin birlikte kullanılmasının gerekliliğini ortaya koymuştur.

Altınışık (2018) çalışmada, Borsa İstanbul'da işlem gören otuz dokuz hisseden oluşan bir portföy havuzundan geleneksel istatistiksel yöntemler ve ML ile oluşturulan iki farklı sekiz hisseden portföyün performansları karşılaştırılmıştır. Geleneksel yöntemde 2016-2020 dönemi verileriyle analizler yapılmış ve en optimize sekiz hisseden portföy oluşturulmuştur. Diğer taraftan, ML yöntemlerine öğretilen verilerle tahminler yapılmış ve en iyi sekiz hisse seçilerek portföy oluşturulmuştur.

Kurucan (2019) yaptığı çalışmada, Borsa İstanbul 100 endeksinin gün içi en yüksek fiyatının tahmin edilmesi için dört ve beş yıllık veri setleri kullanılmıştır. Yapılan analizlerde, ANN ve XGBoost gibi ML teknikleri kullanılmıştır. Sonuçlar, XGBoost yönteminin daha iyi performans gösterdiğini ve oluşturulan yatırım stratejilerinin pasif yatırıma göre daha iyi sonuçlar verdiğini göstermektedir. Ayrıca, modellerin tahmin gücünü artırmak için yapılan denemelerde, aynı günün açılış fiyatının tahminci veri setine eklenmesi etkili olmuştur.

Rong vd. (2022) yaptıkları çalışmada, ticari bankaların temel muhasebe sistemlerinin işlem hacminin doğru bir şekilde tahmin edilmesinin önemine vurgu yapmaktadır. Verilerin zaman serisi özelliklerini inceleyerek, iyileştirilmiş yarasa algoritması ve optimize edilmiş sinir ağı kullanarak bir işlem hacmi tahmin modeli önerilmektedir. Algoritmanın optimizasyon yeteneği, GRU modelinin parametrelerinin belirlenmesinde kullanılmakta ve banka veri ambarındaki tarihçe verileriyle modelin etkinliği değerlendirilmektedir. Sonuçlar, geliştirilmiş modelin diğer modellere göre daha iyi performans gösterdiğini ortaya koymaktadır. Bu birleşik model ticari bankaların temel muhasebe sistemlerinde işlem hacmi tahmini için etkili bir çözüm sunmaktadır.

Dongdong vd. (2019) yaptıkları çalışmada, borsa tahmininde ML algoritmalarının kullanımını ve işlem maliyetinin etkisini incelemektedir. Mevcut borsa tahmin çalışmaları sınırlı veri, kısa test süresi ve işlem maliyetleri gibi gerçekçi olmayan senaryolarda yürütülmüş ve sonuçların istatistiksel olarak anlamlı olup olmadığı sorgulanmıştır. 2010-2017 yılları arasında S&P 500 ve CSI 300 endekslerinden toplam 609 hisse senedi veri seti üzerinde altı geleneksel ML algoritması ve altı derin sinir ağı modeli değerlendirilmiştir. Geleneksel ML algoritmaları, yön tahmini göstergelerinde genel olarak daha iyi performans göstermiştir. Şaşırtıcı bir şekilde, işlem maliyeti hesaba katılmadığında, bazı geleneksel ML algoritmalarının en iyi derin öğrenme modellerinden çok da geride olmadığı görülmüştür. Ayrıca, tüm ML algoritmalarının performansı işlem maliyetindeki değişikliklere duyarlıdır. İşlem maliyetini hesaba katıldığında ise, derin öğrenme modelleri daha iyi performans gösterdiği belirtilmiştir.

Cho vd. (2014), RNN Encoder-Decoder adı verilen bir sinir ağı modelini tanıtmaktadır. Bu model, sembollerin vektör temsillerini oluşturarak çeviri sistemlerinde performansı artırmayı amaçlamaktadır. Araştırma, önerilen modelin dil bilgisel ifadeleri anlamlı bir şekilde temsil ettiğini göstermektedir.

Yamak vd. (2019) yaptıkları araştırmada, zaman serisi tahmini için üç farklı makine öğrenme modelinin (ARIMA, LSTM, GRU) performansı karşılaştırılmıştır. Bitcoin fiyat veri seti kullanılarak yapılan tahminlerde, ARIMA modelinin derin öğrenme tabanlı regresyon modellerinden daha iyi sonuçlar verdiği görülmüştür. ARIMA modeli, MAPE için %2.76 ve RMSE için 302.53 değeriyle en iyi sonuçları verirken, GRU modeli LSTM modelinden daha başarılı bulunmuştur.

Ridwan vd. (2023) çalışmalarında, ARIMA ve GRU modellerinin yüksek frekanslı hisse senedi fiyat verilerini tahmin etmedeki etkililiğini değerlendirmektedir. ARIMA modelinin zaman serisi tahmininde popüler olmasına rağmen, karmaşık doğrusal olmayan desenleri yakalamada sınırlamaları bulunmaktadır. Bu çalışmada, HIMBARA bankalarının dakika düzeyindeki hisse senedi fiyatlarını tahmin etmek için ARIMA ve GRU modelleri karşılaştırılmıştır. Sonuçlar, GRU modelinin ARIMA modelinden daha iyi bir tahmin doğruluğuna sahip olduğunu göstermektedir.

Al-Chalabi vd. (2018) çalışmasında, ARIMA modeli kullanılarak yapılan tahminlerde, ARIMA parametrelerinin (p, d, q) farklı değerlerinin tahmin yeteneklerini önemli ölçüde etkilediği görülmüştür. Dört farklı senaryo kullanılmış ve bu senaryolardan biri uygun tahmin sonuçları vermiştir. Parametre değerlerinin tahmin yöntemine güçlü bir etkisi olduğu için, doğru tahminler için bu parametrelerin verilerden daha iyi tahmin edilmesi gerekmektedir. ARIMA modeline dayalı çok hedefli genetik algoritma (MOGA) gibi yapay zeka yöntemleri, bu parametrelerin (p, d, q) tahmin edilmesinde alternatif imkanlar sunabilir ve veri tahminini iyileştirebilir. MOGA ile elde edilen sonuçlar, yüksek doğruluk seviyesinde veri tahmini sağlayabilir ve tahmin edilen veriler yaşam döngüsü maliyet analizi için kullanılabilir olduğunu göstermiştir.

Kontopoulou vd. (2023) yaptıkları çalışmada, zaman serisi tahmin problemlerine yönelik ARIMA ve makine öğrenimi algoritmalarının karşılaştırılması ve bu iki yaklaşımın hibrit modellerde birleştirilmesi üzerine kapsamlı bir literatür incelemesi yapılmıştır. Çalışmanın sonuçlarına göre, yapay zeka algoritmaları çoğu uygulamada daha iyi tahmin performansı gösterirken, hibrit istatistiksel-yapay zeka modelleri her iki yöntemin de en iyi özelliklerini kullanarak bireysel yöntemlerden daha yüksek düzeyde sonuç vermiştir.

Ahmed vd. (2022) yaptıkları çalışmada, Bu çalışmada, Transformer mimarisinin zaman serisi analizinde kullanımını ele alan bir eğitim sunulmuştur. Çalışmada, kendine dikkat (self-attention) mekanizması, konumsal kodlama (positional encoding), çoklu başlık (multi-head) ve kodlayıcı/çözücü (encoder/decoder) gibi çekirdek bileşenler ayrıntılı bir şekilde açıklanmıştır. Ayrıca, zaman serisi görevlerini ele almak için orijinal Transformer mimarisine yapılan çeşitli iyileştirmeler ve en iyi uygulamalar vurgulanmıştır. Sonuç olarak, bu iyileştirmeler ve teknikler sayesinde Transformer modellerinin zaman serisi analizinde etkin bir şekilde kullanılabileceği ve performanslarının artırılabilceği gösterilmiştir.

Wen vd. (2022) çalışmalarında, Transformer modellerinin zaman serisi analizindeki kullanımını sistematik olarak incelenmiştir. Transformer'ların doğal dil işleme ve bilgisayarla görme alanlarındaki üstün performansları, zaman serisi topluluğunda da büyük ilgi uyandırmıştır. Transformer'ların uzun vadeli bağımlılıkları ve etkileşimleri yakalama yeteneği, zaman serisi modellemesi için özellikle çekici bulunmuştur. Çalışmada, Transformer'ların ağ yapısı perspektifinden yapılan uyarlamalar ve modifikasyonlar ile uygulama perspektifinden tahmin, anomali tespiti ve sınıflandırma gibi görevler için kullanılan zaman serisi Transformer'ları ele alınmıştır. Empirik olarak, Transformer'ların zaman serisi performansını incelemek için sağlam analiz, model boyutu analizi ve mevsimsel-trend ayrışma analizi yapılmıştır. Son olarak, gelecekteki araştırmalar için öneriler sunmuşlardır.

Fang ve Wang (2020) yaptıkları çalışmada, zaman serisi verilerindeki eksik değerlerin derin öğrenme yöntemleri kullanılarak imputasyonu incelenmiştir. Geleneksel yöntemlerin aksine, derin öğrenme modelleri zamansal ilişkileri yakalayabilir ve bu nedenle zaman serisi verilerinde daha etkili sonuçlar verebilir. Çalışma, özellikle Recurrent Neural Network gibi modellerin mimarilerini, avantajlarını ve dezavantajlarını değerlendirerek, bu yöntemlerin zaman serisi imputasyonu alanında kaydettiği ilerlemeleri tartışmıştır. Modellerin gelişimi ve etkileri üzerine yapılan bu inceleme, derin öğrenme tabanlı zaman serisi imputasyon tekniklerinin performansını ve potansiyelini göstermeyi amaçlamış ve özellikle GRU-D, GRUI-GAN ve E2GAN gibi derin öğrenme yöntemleri daha doğru imputasyon sağladığı belirtilmiştir. E2GAN, en güncel ve başarılı yöntem olarak öne çıktığı belirtilmiştir.

Jahangiri vd. (2023) yaptıkları araştırmada, boylamsal çalışmalarda eksik verilerle başa çıkmak için çeşitli imputasyon yöntemleri incelenmiş ve bu çalışmada yöntemleri kesitsel, boylamsal ve kesitsel-boylamsal yaklaşımlar olarak kategorize etmiş ve performanslarını simülasyon ve gerçek veri analizi kullanarak değerlendirmişlerdir.

Fan vd. (2023) yaptıkları çalışmada eksik veri kümelerinin yönetiminde ve teşhis prosedürlerinin geliştirilmesinde ileri istatistiksel ve makine öğrenimi yöntemlerinin etkinliği vurgulamışlardır.

Amusa ve Hossana (2024) yaptıkları çalışmada çeşitli eksik veri tekniklerinin performanslarını araştırmış ve Monte Carlo Simülasyonlarını kullanarak çeşitli algoritmalar ile farklı eksik veri mekanizmalarını karşılaştırmıştır. Bulguları, yöntemlerin etkinliğinin değişken olduğunu ve doğru ve güvenilir sonuçlar elde etmek için eksik veri desenine göre uygun tekniklerin seçilmesinin önemini vurgulamışlardır.

Yürük (2021) yaptığı çalışmada, Türk Hava Yolları hisse senedinin tahmini için ANN yöntemi kullanılarak zaman serisi analizi yapmıştır. 5 farklı yapay sinir ağı modeli oluşturulmuştur. Sonuçlar, oluşturulan yapay sinir ağı modelinin hisse senedi tahminlerinde güçlü bir performans sergilediğini göstermiştir.

Deb (2021) çalışmasında, üç havayolu şirketinin hisse fiyat hareketlerini analiz etmek için yeni bir yaklaşımın benimsemiş ve GARCH modeli uygun şekilde değiştirilmiştir. Bulgular pandemiler sırasında hisse senedi piyasası dinamiklerini anlamak için değerli bilgiler ve ilgili konuları ele almak için esnek bir çerçeve sunmaktadır.

Alıcı ve Sevil (2020) yaptıkları çalışmada, 2005-2018 yılları arasında 28 havayolu işletmesinin iç finansal faktörleri ile hisse senedi fiyatları arasındaki ilişki incelenmiştir. Panel veri ve panel VAR analiz yöntemleri kullanılarak yapılan analizler, toplam aktiflerin hisse senedi fiyatlarını pozitif, finansal kaldıraçın ise negatif etkilediğini göstermiştir.

Muttalib ve Pasigai (2023) yaptıkları çalışmada, Endonezya Borsası'nda halka açık olan havayolu şirketlerinin hisse senedi fiyatları üzerinde Yatırım Getirisi'nin (ROI) etkisi incelenmiştir. Regresyon analizi kullanılarak yapılan araştırma, yüksek ROI'nin hisse senedi fiyatlarını olumlu yönde etkilediğini göstermiştir. Yatırımcılar, yüksek ROI sağlayan şirketlere daha fazla önem vermektedir. Ayrıca, ekonomik büyüme, sektör

rekabeti ve makroekonomik faktörler gibi unsurların da hisse senedi fiyatları üzerinde etkili olduğu belirtilmiştir. Çalışma, ROI'nin havacılık sektöründeki şirketlerin değerini ve hisse senedi fiyatlarını değerlendirmedeki önemini vurgulamaktadır.



2. FİNANSAL PİYASALAR, İSTATİSTİKSEL ANALİZ VE EKSİK VERİ

Finansal piyasalar, ekonomik aktiviteleri ve piyasa hareketlerini anlamak için kullanılan çeşitli analiz yöntemleriyle karmaşık yapıları ve dinamikleri ifade eder. Bu analiz yöntemleri arasında zaman serisi analizi ve eksik veri problemi, finansal verilerin doğruluğu ve güvenilirliği açısından büyük önem taşır. İstatistiksel analiz yöntemleri, finansal piyasa verilerinin modellenmesinde ve tahmin edilmesinde kritik rol oynar (Brockwell, 2002).

2.1. Finansal Sistem ve Finansal Piyasa Kavramı

Finansal sistem, ekonomideki para ve diğer finansal varlıkların aktarılması işlemlerini kolaylaştıran kurumlar, piyasalar, araçlar ve yöntemler bütünüdür. Bu sistem, tasarrufların yatırıma dönüşmesine olanak tanıyan temel bir mekanizmadır. Fonların etkin bir şekilde dağıtılmasını sağlayan finansal sistem, bu işlevini finansal piyasalar aracılığıyla gerçekleştirir (Türkiye Cumhuriyet Merkez Bankası, 2015).

Finansal piyasaların sınıflandırılması çeşitli kriterlere göre yapılabilir, ancak en yaygın ayırım para ve sermaye piyasaları şeklindedir. Bu ayırım, finansal varlıkların vadelerine göre gerçekleştirilir (Babuşcu, 2017). Kısa vadeli finansal araçların işlem gördüğü piyasalar para piyasası olarak tanımlanırken, uzun vadeli finansal araçların ticaretinin yapıldığı piyasalar sermaye piyasası olarak adlandırılır. Bu sınıflandırma, finansal araçların vadesine bağlı olarak piyasaların işlev ve yapılarını belirginleştirir (Gündoğdu, 2016).

Hisse senedi, sermayesinin belli bir kısmını temsil eden, ilgili yasa şartlarına uygunluğu onaylanmış ve bu doğrultuda düzenlenmiş kıymetli evraklardır (Bozkurt, 1988). Şirketin sahipliğini gösteren bu belgeler, sahiplerine şirket karlarından pay alma, şirket yönetimine katılma ve şirket genel kurullarında oy kullanma gibi bir takım haklar sağlamaktadır (Bozkurt, 1988). Hisse senetleri, borsalarda işlem görür ve yatırımcıların sermaye kazancı elde etmelerini sağlamakta olup aynı zamanda ekonomik koşullara ve şirketin performansına bağlı olarak değer kaybedebilir. Hisse senetleri, ekonomik büyümeye katkıda bulunurken, yatırımcılara şirket üzerinde söz sahibi olma bir takım fırsatlar sunar ve böylece finansal piyasaların temel yapı taşlarından birini oluşturur (Babuşcu, 2017).

Hisse senedi piyasası, şirketlerin sermaye artırımını yapmak için hisse senetlerini halka arz ettiği ve yatırımcıların bu senetleri alıp sattığı organize bir pazar yeridir (Ertunç, 2023). Piyasanın işleyişi, arz ve talep dinamiklerine, şirketlerin performansına ve ekonomik göstergelere bağlı olarak değişkenlik gösterir. Borsalarda, hisse senetleri belirli saatlerde, aracı kurumlar ve borsa katılımcıları aracılığıyla alınıp satılır. İşlem süreci, yatırımcıların emirlerini elektronik bir sistem üzerinden iletmeleriyle başlar (Gündoğdu, 2016). Bu emirler piyasa yapımcılar tarafından toplanır, fiyatlandırılır ve eşleştirilir. Sonuçta, alıcı ve satıcı arasında bir anlaşma sağlanarak işlem tamamlanır (Doğru ve Nacakcı, 2014).

2.2. Hisse Senetleri Değerlemesinde Kullanılan Yöntemler

2.2.1. Temel analiz ve hisse senedi değerlendirme

Temel analiz, hisse senetlerinin değerlendirilmesi için kullanılan bir yöntemlerden biri olup şirketlerin finansal durumları, sektör koşulları ve ekonomik faktörler gibi çeşitli değişkenleri kapsamlı bir şekilde inceler. Bu analiz türü, bir şirketin gelecekteki büyüme potansiyelini, finansal durumunu ve hisse senedinin adil değerini anlamak için kullanılır. Bu değer hesaplanması üç aşamalı bir süreçten geçer: İlk olarak, ülke ekonomisinin durumu ve bu durumun şirket karlılığı üzerindeki etkileri değerlendirilir. İkinci aşamada, şirketin faaliyet gösterdiği endüstrinin konumu incelenir. Üçüncü ve son aşamada ise şirketin yönetim yetenekleri, kullanım potansiyeli ve finansal durumundaki gelişmeler ele alınır. Temel analiz, bu üç aşama sonucunda elde edilen bilgilerin sistematik bir şekilde değerlendirilmesi ve tahmin yapılması sürecidir (Bozkurt, 1988). Temel analiz, hisse senedi yatırımcılarına uzun vadeli perspektifler sunarak, bilinçli yatırım kararları alınmasına yardımcı olur.

2.2.2. Teknik analiz ve hisse senedi değerlendirme

Teknik analiz, sermaye piyasalarında yaygın olarak kullanılan önemli bir analiz yöntemidir. Bu yöntem, hisse senetlerinin geçmiş performanslarına dair toplanmış tarihsel veriler üzerinde matematiksel hesaplamalar, çeşitli formasyonlar ve indikatörler kullanarak gelecekteki fiyat hareketlerini tahmin etmeye çalışır. Teknik analiz, esas olarak piyasa davranışlarını ve trendleri belirlemeye odaklanır ve yatırımcılara hisse senedi alım-satım kararlarında rehberlik eder. (Kılınçarslan, 2022)

Bu yöntem, hisse senetlerinin geçmiş fiyat ve hacim verilerini matematiksel modeller ve çeşitli göstergeler aracılığıyla analiz eder. Örneğin, hareketli ortalamalar,

RSI (Relative Strength Index) ve MACD (Moving Average Convergence Divergence) gibi teknik göstergeler, piyasadaki trendlerin ve potansiyel dönüş noktalarının belirlenmesinde kullanılır. Teknik analiz, özellikle kısa ve orta vadeli yatırım stratejileri geliştirirken, piyasa psikolojisi ve tüccar davranışlarının etkilerini anlamada etkili bir araç olarak görülür. Bu, yatırımcılara piyasa koşullarını daha iyi değerlendirme ve zamanlama yeteneği kazandırarak hisse senedi alım-satım kararlarını optimize etme fırsatı sunar (Kılınçarslan, 2022).

Teknik analiz, hisse senedi fiyatlarının neden yükseldiği veya düştüğü konusundaki sebeplerle ilgilenmez. Bunun yerine, fiyat hareketlerini yönlendirebilecek çeşitli faktörlerin (spekülasyon, manipülasyon, arz ve talepteki değişiklikler gibi) karmaşık doğasını kabul eder. Teknik analizin asıl amacı, geçmişteki piyasa verileri ve fiyat dalgalanmalarını inceleyerek, bu trendlerin gelecekte tekrarlanma olasılığını değerlendirip buna göre alım veya satım kararı vermektir. Bu yaklaşım, piyasa formasyonlarını ve trendleri kullanarak yatırım kararlarına yön verir.

Teknik analiz, hisse senedi ve diğer finansal varlıkların fiyat hareketlerini tahmin etmek için kullanılan bir dizi yöntem ve araç içerir. Teknik analizde sıkça kullanılan bazı yöntemler şunlardır:

- Trend Çizgileri: Trend çizgileri, fiyat grafiklerinde destek ve direnç seviyelerini belirlemek için çizilir. Bu çizgiler, fiyatların hangi yönde hareket etme eğiliminde olduğunu gösterir (Varlık, 2017).
- Hareketli Ortalamalar: Hareketli ortalamalar, belirli bir zaman dilimi boyunca ortalama fiyatları gösterir ve fiyatların genel yönünü anlamak için kullanılır. En popüler hareketli ortalamalar arasında basit hareketli ortalama (SMA) ve üssel hareketli ortalama (EMA) bulunur.
- Göstergeler ve Osilatörler: RSI (Relative Strength Index), MACD (Moving Average Convergence Divergence), ve Stokastik Osilatör gibi teknik göstergeler, aşırı alım veya satım koşullarını ve potansiyel trend değişikliklerini tespit etmeye yardımcı olur.
- Formasyonlar: Fiyat hareketleri bazen belirli desenler oluşturur. Bu formasyonlar, “baş ve omuzlar”, “bayrak”, “flama” ve “üçgen” gibi isimler alabilir ve gelecekteki fiyat hareketlerini tahmin etmek için kullanılır.

- Fibonacci Düzeltmesi: Fiyatların, büyük bir hareketten sonra belirli bir yüzde geri çekileceği öngörülür. Fibonacci düzeyleri, potansiyel destek ve direnç seviyelerini belirlemek için kullanılır.

Bu yöntemler, yatırımcılara piyasa davranışlarını ve potansiyel fiyat değişimlerini anlamada rehberlik eder ve daha bilinçli yatırım kararları alabilmelerine olanak tanır. Yatırımcılar, tek bir yöneme bağlı kalmak yerine çeşitli teknik analiz yöntemlerini bir arada kullanarak yatırım kararları almaları, daha sağlam ve güvenilir yatırım fırsatları sunacaktır.

2.2.3. Grafik analizi ve trendlerin incelenmesi

Grafik analizi ve trendlerin incelenmesi, teknik analizin temel bileşenlerindendir ve yatırımcılara piyasa eğilimlerini anlama konusunda kritik bilgiler sağlar. Grafikler, fiyat hareketlerinin görsel temsilleridir ve çeşitli zaman dilimlerindeki fiyat değişikliklerini yansıtarak trendleri belirlemede yardımcı olur. Yatırımcılar, yükselen, düşen ve yatay trendleri grafikler üzerinden tespit edebilirler (Kuzu, 2017). Yükselen trendler genellikle alım sinyali olarak değerlendirilirken, düşen trendler satış sinyali verebilir. Trend çizgileri, destek ve direnç seviyeleri gibi araçlar da fiyatın potansiyel hareket yönünü tahmin etmek için kullanılır. Bu analiz yöntemi, piyasadaki genel duyarlılığı ölçmek ve fiyatın gelecekte izleyebileceği muhtemel yolları öngörmek için etkili bir yol sunar, böylece yatırımcılar daha bilinçli yatırım kararları alabilirler (Ergül, 2009).

Grafik analiz yöntemleri, yatırımcılara piyasalardaki trendlerin ve fiyat hareketlerini görsel olarak inceleme ve yorumlama imkanı sağlar (Varlık, 2017). Grafik ve trendlerin incelenmesi konusunda kullanılan başlıca analiz yöntemleri:

- Çizgi Grafikleri (Line Charts): En basit grafik türü olan çizgi grafikleri, belirli bir zaman dilimi boyunca fiyatların kapanış değerlerini birbirine bağlayan bir çizgi ile gösterir. Trendlerin genel yönünü anlamak için kullanılır.
- Bar Grafikleri (Bar Charts): Her bir bar, belirli bir zaman dilimindeki en yüksek, en düşük, açılış ve kapanış fiyatlarını gösterir. Bu grafikler, fiyat hareketlerinin daha detaylı bir analizini sunar.
- Mum Grafikleri (Candlestick Charts): Japonya'da geliştirilen bu grafik türü, bar grafiklerine benzer bilgileri içerir ama görsel olarak daha fazla bilgi

sunar. Açılış ve kapanış fiyatları arasındaki alan genellikle renklendirilir (genellikle yeşil yükseliş, kırmızı düşüş için) ve bu da piyasa duyarlılığını anlamayı kolaylaştırır.

- **Hacim Grafikleri (Volume Charts):** Hacim grafikleri, belirli bir zaman diliminde gerçekleşen işlem miktarını gösterir ve genellikle fiyat grafiklerinin altında yer alır. Fiyat hareketlerinin gücünü ve meşruiyetini değerlendirmek için kullanılır.
- **Nokta ve Figür Grafikleri (Point and Figure Charts):** Bu grafikler, fiyat hareketlerini belirli bir miktar değişiklik olmadıkça göstermez, böylece küçük ve önemsiz fiyat dalgalanmalarını filtreler. Trendler ve destek/direnç seviyelerini belirlemede etkilidir.
- **Heikin-Ashi Grafikleri:** Mum grafiklerine benzeyen bu grafik türü, fiyat hareketlerini daha pürüzsüz ve daha az gürültülü göstermek için özel bir hesaplama kullanır. Trendin yönünü ve gücünü tespit etmek için tercih edilir.

Bu grafik analiz yöntemleri, yatırımcılara piyasaları farklı perspektiflerden değerlendirme şansı vererek, daha bilinçli yatırım kararları almalarını sağlar. Her bir grafik türü, belirli bir analiz ihtiyacına hizmet eder ve piyasaları detaylı olarak analiz etmek için bu yöntemlerden bir veya birden fazlasını kullanılır (Ergül, 2009).

2.3. Hisse Senedi Değerlemesinde Zaman Serisi Analizi

Finansal piyasalarda hisse senedi fiyatlarının analiz edilmesi ve gelecekteki fiyat hareketlerinin tahmin edilmesi, yatırım kararlarının alınmasında kritik bir rol oynar. Bu bağlamda, zaman serisi analizi, hisse senedi fiyatlarının geçmiş verilerine dayanarak gelecekteki eğilimleri ve paternleri tahmin etmek için kullanılan güçlü bir yöntemdir.

Zaman serisi verileri belirli bir zaman aralığında düzenli olarak toplanan gözlemlerden oluşur. Hisse senedi fiyatları, günlük, haftalık veya aylık olarak kaydedilir ve bu veriler, trend, mevsimsellik ve rastgele bileşenler içerir (Agrawal, 2013). Zaman serisi analizi, bu bileşenleri ayrıştırarak hisse senedi fiyatlarının dinamiklerini anlamaya çalışır (Shumway ve Stoffer, 2017).

Temel Zaman Serisi Modelleri:

1. Hareketli Ortalama (Moving Average) ve Üstel Düzleştirme (Exponential Smoothing):

Hareketli ortalama ve üstel düzleştirme yöntemleri, hisse senedi fiyatlarındaki kısa vadeli dalgalanmaları düzleştirmek ve genel trendi belirlemek için kullanılır. Bu yöntemler, fiyat verilerinin daha pürüzsüz hale getirilmesini sağlar ve mevsimsellik etkilerini belirlemekte yardımcı olur (Wen ve Li, 2023).

2. Otoregresif Entegre Hareketli Ortalama (ARIMA) Modeli:

ARIMA modeli, hisse senedi fiyatlarının geçmiş değerlerine dayanarak gelecekteki değerlerini tahmin etmek için kullanılan yaygın bir yöntemdir. ARIMA(p,d,q) modeli, otoregresif (AR), entegre (I) ve hareketli ortalama (MA) bileşenlerini birleştirerek, fiyat serilerindeki trend ve mevsimsellik gibi özellikleri yakalar (Kaynar, 2009).

3. GARCH Modelleri (Generalized Autoregressive Conditional Heteroskedasticity):

GARCH modelleri, hisse senedi fiyatlarının volatilitelerini modellemek için kullanılır. Bu modeller, fiyat dalgalanmalarının zaman içindeki değişkenliğini tahmin ederek, yatırımcıların risk yönetimi stratejilerini geliştirmelerine yardımcı olur (Kaynar, 2009).

Zaman serisi analizi, borsa hisse senedi fiyatlarının dinamiklerini anlamak ve gelecekteki hareketleri tahmin etmek için kritik bir araçtır. Temel istatistiksel yöntemler ve derin öğrenme modelleri, hisse senedi analizinde kullanılarak yatırımcıların daha bilinçli kararlar almasına yardımcı olur.

Zaman serisi analizi, finansal verilerin zaman içindeki hareketlerini inceleyerek gelecekteki eğilimleri tahmin etmeye çalışır. Bu analiz yöntemi, verilerin düzenli aralıklarla toplanan gözlemlerden oluştuğu durumlarda özellikle etkilidir. Zaman serisi analizinde kullanılan başlıca yöntemler ARIMA, GARCH, VAR modelleridir (Hyndman, 2018).

Zaman serisi analizlerinde eksik veri, veri toplama süreçlerindeki hatalar, cihaz arızaları veya kesintiler nedeniyle sıkça karşılaşılan bir sorundur. Eksik veriler, zaman serisi modellemesinin doğruluğunu ve güvenilirliğini olumsuz etkileyebilir, bu nedenle

bu verilerin uygun şekilde işlenmesi gereklidir. İmputasyon yöntemleri, eksik veri noktalarını tahmin ederek, veri setinin bütünlüğünü korur ve analizlerin daha tutarlı ve güvenilir sonuçlar vermesini sağlar (Wang vd., 2024).

2.3.1. Zaman serisinde eksik veri

Zaman serisi analizlerinde eksik veri problemi, verilerin doğruluğunu ve güvenilirliğini önemli ölçüde etkileyen yaygın bir durumdur. Bu eksiklikler, veri toplama süreçlerindeki hatalardan, cihaz arızalarından veya sistem kesintilerinden kaynaklanabilir. Eksik veriler, analiz sonuçlarını ve modellerin performansını olumsuz etkileyebilir, bu nedenle bu verilerin uygun şekilde işlenmesi kritik bir öneme sahiptir.

Eksik veri probleminin çözümü için kullanılan yöntemlerden biri imputasyondur. İmputasyon, eksik veri noktalarının mantıklı tahminlerle doldurulması sürecidir. Bu yöntem, veri setinin bütünlüğünü koruyarak analizlerin daha tutarlı ve güvenilir sonuçlar vermesini sağlar. Basit imputasyon yöntemleri arasında ortalama ile doldurma, lineer interpolasyon, spline interpolasyonu ve Stineman interpolasyon teknikleri bulunur (Wang vd., 2024).

Bu yöntemler, verilerin zaman içindeki dinamiklerini ve ilişkilerini öğrenerek eksik verilerin doldurulmasında üstün performans gösterir. Sonuç olarak, zaman serisi analizlerinde eksik veri probleminin çözülmesi, verilerin daha sağlıklı ve güvenilir analizler yapılmasını mümkün kılar, bu da karar alma süreçlerini ve öngörülerini geliştirir (Fang ve Wang, 2020).

3. YÖNTEM

Zaman serisi analizlerinde, eksik verilerin doğru bir şekilde işlenmesi, analiz sonuçlarının güvenilirliği ve doğruluğu açısından son derece önemlidir. Eksik veriler, çeşitli nedenlerle ortaya çıkabilir ve bu durum, verinin kalitesini ve analizlerin doğruluğunu olumsuz etkileyebilir. Eksik verilerin yerine konulması, eksik veri problemini çözmek için kullanılan yaygın bir yöntemdir. İmputasyon teknikleri, eksik verileri tahmin ederek veya doldurarak veri setinin tamamlanmasını sağlar. Bu teknikler, eksik verilerin neden olduğu bilgi kaybını en aza indirmeyi amaçlar ve analiz sonuçlarının güvenilirliğini artırır. Yaygın imputasyon yöntemleri arasında lineer imputasyon, spline imputasyon, Stineman imputasyon, ortalama imputasyon ve rasgele imputasyon bulunmaktadır. Her bir yöntem, farklı veri setleri ve eksik veri tipleri için uygun çözümler sunar ve belirli koşullar altında daha etkili olabilir. Bu çalışmada, çeşitli imputasyon yöntemlerinin performansları ve üstünlükleri incelenmiştir.

Zaman serisi analizinde yaygın olarak kullanılan yöntemlerden biri olan derin öğrenme, makine öğrenmesinin bir alt dalı olarak, çok katmanlı ANN kullanarak veri analizinde ileri düzeyde performans sergileyen bir tekniktir (Alpaydın, 2020). Derin öğrenme algoritmaları, büyük veri kümelerinden öğrenerek, karmaşık desenleri ve ilişkileri keşfetmekte ve bu sayede görüntü tanıma, doğal dil işleme, ses tanıma ve daha birçok alanda üstün sonuçlar elde etmektedir. Özellikle büyük veri kümelerinin analizinde ve yüksek doğruluk gerektiren uygulamalarda derin öğrenme teknikleri, geleneksel ML yöntemlerine göre daha etkili çözümler sunmaktadır (Goodfellow, 2016).

Bu çalışmada, İmputasyon teknikleri olarak lineer, spline, Stineman, ortalama ve rastgele imputasyon yöntemleri incelenmiştir. Bu yöntemlerin performansları ve üstünlükleri, eksik verilerin zaman serisi analizine olan etkilerini azaltmak için değerlendirilmiştir. Diğer taraftan yenilikçi zaman serisi yaklaşımlarından RNN, LSTM, GRU ve Transformer modelleri kullanılmıştır. Bu yöntemlerin eksik veri durumunda, istatistiksel yöntemlere göre üstünlükleri tartışılmıştır.

3.1. İmputasyon Teknikleri

3.1.1. Lineer imputasyon

Zaman serisi analizinde kayıp verilerin doldurulması, model performansını ve tahminlerin doğruluğunu artırmak için kritik bir adımdır. Lineer imputasyon, eksik verilerin doldurulmasında yaygın olarak kullanılan yöntemlerden biridir (Shumway ve

Stoffer, 2017). Bu yöntem, eksik veri noktalarını, çevresindeki bilinen veri noktaları arasında doğrusal bir doğrultu izleyerek tahmin eder. Lineer imputasyonun temel prensibi, veri noktalarının doğrusal bir ilişki içinde olduğu varsayımına dayanır (Little, 2019). Eksik bir veri noktası, hemen önceki ve sonraki bilinen veri noktaları arasındaki eğim kullanılarak tahmin edilir. Bu yöntem, veri setinde doğrusal ilişkilerin güçlü olduğu durumlarda oldukça etkilidir ve basitliği ile öne çıkar. Ancak, verilerin doğrusal olmadığı veya karmaşık ilişkiler içerdiği durumlarda, bu yöntemin sınırlamaları olabilir. Lineer imputasyonun doğru ve etkin kullanımı, zaman serisi analizlerinde daha güvenilir sonuçlar elde edilmesine katkıda bulunur (Hyndman, 2018).

Lineer imputasyon formülü şu şekildedir:

$$x_t = x_{t-1} + \frac{(x_{t+1} - x_{t-1})}{(t+1 - (t-1))} (t - (t-1)) \quad (3.1)$$

Lineer imputasyon, eksik veriyi tahmin ederken, eksik verinin bulunduğu veri noktasının öncesindeki ve sonrasındaki komşu verileri kullanır. Bu yöntem, eksik veri noktası x_t için, eksik verinin öncesindeki x_{t-1} ve sonrasındaki x_{t+1} veri noktalarını kullanarak bir lineer interpolasyon yapar.

3.1.2. Spline imputasyon

Spline imputasyon, zaman serisi analizinde kayıp verilerin doldurulmasında kullanılan etkili yöntemlerden biridir (Little, 2019). Bu yöntem, eksik veri noktalarını doldururken polinomların bir kombinasyonunu kullanarak daha esnek ve uyumlu bir eğri oluşturur. Spline fonksiyonları, belirli aralıklarla tanımlanan polinom parçalarından oluşur ve bu parçalar, aralıklarda sürekli bir eğim ve sürekli bir eğrilik sağlayacak şekilde birleştirilir (Hastie, 2009). Spline imputasyonun temel avantajı, veri setindeki ani değişikliklere ve doğrusal olmayan ilişkilere daha iyi uyum sağlamasıdır (Little, 2019).

Özellikle, kübik spline imputasyonu yaygın olarak kullanılır ve üçüncü dereceden polinomları kullanarak daha pürüzsüz ve gerçekçi tahminler yapar (Eubank, 1999). Eksik veri noktalarının çevresindeki bilinen veri noktalarına dayalı olarak, spline fonksiyonları eksik değerleri tahmin eder ve bu tahminler, doğrusal yöntemlere kıyasla daha yüksek bir hassasiyet ve esneklik sunar (Schumaker, 2007). Ancak, spline imputasyonun karmaşıklığı ve hesaplama maliyeti doğrusal yöntemlere göre daha yüksektir. Bu nedenle, bu yöntemin seçimi veri setinin doğası ve analiz amaçlarına bağlı olarak dikkatlice

yapılmalıdır (De Boor, 2001). Spline imputasyon, veri setinde doğrusal olmayan ve karmaşık ilişkilerin olduğu durumlarda etkili bir çözüm sunar.

Spline imputasyon, eksik veriyi tahmin ederken, eksik verinin öncesindeki ve sonrasındaki mevcut veri noktalarını kullanarak spline eğrileri oluşturur. Bu eğriler, eksik verinin olduğu bölgeyi daha doğru bir şekilde temsil eder. Spline fonksiyonları genellikle kübik spline olarak kullanılır ve bu durumda, eksik veri noktası x_t için tahmin şu şekildedir:

$$x_t = S(t) \quad (3.2)$$

Burada $S(t)$, verinin zaman t noktasındaki spline fonksiyonunu temsil eder. Spline fonksiyonları, belirli veri noktaları arasında kübik polinomlar kullanılarak oluşturulur ve bu polinomlar birleştirilerek sürekli ve türevlenebilir bir eğri elde edilir (Eubank, 1999).

$$S(t) = a(t - t_0)^5 + b(t - t_0)^4 + c(t - t_0)^3 + d(t - t_0)^2 + e(t - t_0) + f \quad (3.3)$$

Burada, a , b , c , d , e ve f katsayıları, spline fonksiyonunun parametreleridir ve mevcut veri noktalarına göre hesaplanır.

3.1.3. Stineman imputasyon

Stineman imputasyonu, kayıp verilerin doldurulmasında kullanılan nispeten az bilinen ancak etkili bir yöntemdir. Bu yöntem, doğrusal ve eğrisel interpolasyon tekniklerinin avantajlarını birleştirir. Stineman interpolasyonu, eksik veri noktalarını, bilinen veri noktaları arasında sürekli ve pürüzsüz bir eğri oluşturarak tahmin eder (Stineman, 1980). Bu yöntem, doğrusal interpolasyonun basitliğini korurken, eğrisel interpolasyonun esnekliğini sunar.

Stineman imputasyonunun temel prensibi, her bir veri noktasının eğimini hesaplarken, komşu noktaların eğimlerini de dikkate almasıdır (De Boor, 2001). Bu şekilde, eksik bir veri noktası için tahmin edilen değer, çevresindeki bilinen veri noktalarının eğilimlerine göre ayarlanır. Bu yaklaşım, özellikle veri setlerinde ani değişiklikler veya doğrusal olmayan ilişkiler olduğunda daha iyi sonuçlar verebilir (Press, 2007). Stineman yöntemi, eksik verileri tahmin ederken doğrusal interpolasyonun pürüzsüzlüğünü ve eğrisel interpolasyonun esnekliğini bir arada sunar, bu da daha gerçekçi ve uyumlu tahminler yapılmasını sağlar (Stineman, 1980).

Stineman interpolasyon formülü şu şekildedir:

$$x_t = x_{t-1} + (x_{t+1} - x_{t-1}) \frac{(t-(t-1))}{(t+1)-(t-1)} f\left(\frac{(t-(t-1))}{(t+1)-(t-1)}, \frac{x_{t+1} - x_{t-1}}{(t+1)-(t-1)}\right) \quad (3.4)$$

Burada f fonksiyonu, doğrusal olmayan bir düzeltme fonksiyonudur ve Stineman interpolasyonuna özgüdür (Stineman, 1980).

Bu yöntemin avantajları arasında, veri setindeki ani değişimlere uyum sağlayabilmesi ve hesaplama açısından nispeten daha basit olması yer alır. Ancak, veri setinin doğasına ve eksik verilerin dağılımına bağlı olarak, Stineman imputasyonunun etkinliği değişebilir (Akima, 1970). Dolayısıyla, bu yöntemin kullanımı, veri setinin özelliklerine ve analiz amaçlarına göre dikkatlice değerlendirilmelidir (De Boor, 2001).

3.1.4. Ortalama imputasyon

Ortalama imputasyonu, kayıp verilerin doldurulmasında en basit ve yaygın olarak kullanılan yöntemlerden biridir. Bu yöntem, eksik veri noktalarını, veri setindeki mevcut değerlerin ortalamasıyla doldurur (Little, 2019). Ortalama imputasyonunun uygulanması oldukça kolaydır ve hızlı bir şekilde sonuç verir, bu yüzden genellikle büyük veri setlerinde veya hızlı çözümler gerektiren durumlarda tercih edilir (Enders, 2010).

Ortalama imputasyonunun temel prensibi, eksik bir veri noktasının, aynı değişkenin mevcut tüm değerlerinin aritmetik ortalaması alınarak tahmin edilmesidir (Allison, 2002). Bu yöntem, veri setindeki eksik değerlerin eşit bir şekilde dağıldığı ve ortalamanın veriyi iyi temsil ettiği varsayımına dayanır.

Bu yöntem, eksik veri noktası x_t için tahmini şu şekilde yapar:

$$x_t = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.5)$$

Burada N , eksik verilerin bulunduğu sütundaki mevcut veri sayısını, x_i ise bu sütundaki mevcut veri noktalarını temsil eder.

3.1.5. Rasgele imputasyon

Rasgele imputasyon (random imputation), eksik verilerin doldurulmasında kullanılan bir diğer yöntemdir. Bu yöntem, eksik veri noktalarını, veri setindeki mevcut değerlerden rastgele seçilerek doldurur (Schafer, 1997). Rasgele imputasyonun amacı, eksik verilerin doldurulmasında daha doğal ve çeşitli bir yaklaşım sunarak veri setindeki orijinal dağılımı ve değişkenliği korumaktır (Little, 2019).

Rasgele imputasyonun temel prensibi, eksik bir veri noktasının, aynı değişkenin mevcut değerleri arasından rastgele seçilen bir değer ile doldurulmasıdır. Bu yöntem, veri setindeki değişkenlerin dağılımını ve varyansını koruma avantajına sahiptir (Allison, 2002).

Rasgele imputasyon, eksik veriyi tahmin ederken, eksik verinin bulunduğu sütundaki mevcut verilerden rastgele bir değer seçer. Bu yöntem, eksik veri noktası x_t için tahmini şu şekilde yapar:

$$x_t = x_r \quad (3.6)$$

Burada x_r , eksik verilerin bulunduğu sütundaki mevcut veri noktalarından rastgele seçilen bir değeri temsil eder.

3.2. Zaman Serisi Analizinde Derin Öğrenme

Zaman serisi analizi, belirli bir zaman diliminde kaydedilen veri noktalarının incelenmesi ve gelecekteki değerlerin tahmin edilmesi sürecidir. Bu analiz yöntemi, finansal piyasalardan hava durumu tahminlerine kadar geniş bir uygulama alanına sahiptir. Zaman serisi analizi, verilerdeki mevsimsellik, trend ve döngüsel değişiklikleri tanımlamaya ve bu bilgileri kullanarak modelleme yapmaya odaklanır (Karcıoğlu vd., 2021).

ML, bilgisayarların geçmiş deneyimlerden elde ettikleri bilgi ve tecrübeleri kullanarak bir model oluşturduğu ve bu model sayesinde gelecekteki benzer olaylar hakkında kararlar alıp, problemleri çözebildiği bir yapay zeka dalıdır. (Pulat, 2021) . ML, istatistiksel modeller ve yapay zeka tekniklerini kullanarak, belirli bir programlama veya sürekli insan müdahalesi olmaksızın, deneyimlerden otomatik olarak öğrenebilme kabiliyetine sahiptir. Bu öğrenme süreci, veri setlerinden karmaşık desenleri ve ilişkileri tespit ederek, gelecekteki veriler üzerinde tahminlerde bulunmalarını sağlar.. Bu sistemler, belirli bir iş için önceden programlanmamış olup, örüntüleri tanıma ve yeni tahminler yapma yeteneğiyle donatılmıştır (Alpaydın, 2020). Özellikle belirsiz durumların olduğu alanlarda, borsa hareketlerinin tahmini gibi konularda başvurulur.

Derin öğrenme, makine öğrenmesinin bir alt dalı olup verilerden otomatik olarak özellikleri veya desenleri çıkarım yapma ve bu bilgileri sınıflandırma ya da tahmin etme yeteneğine sahip yapay sinir ağlarını kullanır. İnsan beyninin işleyişinden ilham alarak tasarlanan bu algoritmalar, hataları en aza indirmeyi ve her aşamada daha iyi sonuçlar

elde etmek için gerekli iyileştirmeleri yapmayı amaçlar. Bu yöntem, her iterasyonda daha doğru sonuçlar üretmeye yönelik iyileştirmeleri içerir (Marr, 2018). Bu yöntem, çok katmanlı sinir ağları kullanarak karmaşık veri yapılarını ve insan algısını taklit etme kapasitesiyle öne çıkar. Derin öğrenme modelleri, katmanlar halinde bilgi işleyerek görsel ve işitsel gibi yüksek boyutlu ve karmaşık verilerde önemli başarılar elde etmiştir (LeCun vd., 2015). Günümüzde ses tanıma, görüntü işleme ve doğal dil işleme gibi alanlarda derin öğrenme, özellikle büyük verilerin işlenmesinde ve anlamlandırılmasında önemli bir yere sahiptir.

3.2.1. Gözetimli öğrenme

Gözetimli öğrenme, ML modellerinin en yaygın kullanılan türlerinden biridir. Bu yöntemde, algoritma eğitim sürecinde hem girdileri (özellikler) hem de bu girdilere karşılık gelen çıktıları (etiketler) içeren etiketlenmiş veri setleri kullanır. Amacı, verilen girdilere dayanarak çıktıları tahmin edebilen bir model oluşturmaktır. Model, mevcut verilere dayanarak ağırlıkları güncelleyerek doğru sonuçları elde etmeye çalışır ve genelleştirme yaparak bu bilgileri benzer gelecekteki senaryolarda kullanır. Bu, modelin tahminlerinin gerçek sonuçlarla karşılaştırılarak doğrulanması ve ağırlıkların buna göre ayarlanması anlamına gelir (Turan, 2019).

3.2.2. Gözetimsiz öğrenme


Gözetimsiz öğrenme, etiketlenmemiş verilerle çalışır; yani verilerin hangi kategoriye ait olduğu bilgisi model tarafından önceden bilinmez. Bu yöntemin temel amacı, veri setindeki yapıyı veya desenleri keşfetmektir. Gözetimsiz öğrenme, veri setindeki benzer özellikleri taşıyan örnekleri gruplandırarak (kümeleme) veya veri setinin boyutunu azaltarak (boyut indirgeme) kullanılır. Örneğin, müşteri segmentasyonu, genetik kümelenme veya sosyal ağ analizi gözetimsiz öğrenme ile yapılabilir.

3.2.3. Pekiştirmeli öğrenme

Pekiştirmeli öğrenme, bir sistemi maksimize etmek amacıyla hangi eylemlerin yapılması gerektiğini öğrenmesini içerir. Bu modelde, sistem çevreden geri bildirim (ödül veya ceza) alır ve sistem bu geri bildirimlere dayanarak kararlarını günceller. Pekiştirmeli öğrenme, oyun teorisinden robotik uygulamalara, otomatik sürüş sistemlerinden gerçek zamanlı karar verme sistemlerine kadar geniş bir kullanım alanına sahiptir. Bu yöntem, sistemin deneme-yanılma yoluyla optimal stratejiler geliştirmesini sağlar.

3.2.4. Aktivasyon fonksiyonu

Aktivasyon fonksiyonu, derin öğrenme modellerinin temel bileşenlerinden biri olup, yapay nöronların çıktılarını belirleyen matematiksel bir işlemdir. Bu fonksiyonlar, modelin karmaşık veri ilişkilerini öğrenmesini ve nöronlar arasında doğrusal olmayan ilişkiler kurmasını sağlar (Goodfellow, 2016). Aktivasyon fonksiyonları, bir nöronun girdilerinin ağırlıklı toplamını alarak bu toplamı belirli bir aralıkta sınırlı bir çıkışa dönüştürür. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında Sigmoid, Tanh ve ReLU (Rectified Linear Unit) bulunur. Şekil 2.1.'de ilgili üç aktivasyon fonksiyon sunulmuştur (Sharma vd., 2020). Sigmoid fonksiyonu, çıktıları 0 ile 1 arasında sınırlar ve özellikle olasılık tahminlerinde kullanılır (Nielsen, 2019). Tanh fonksiyonu ise çıktıları -1 ile 1 arasında sınırlandırarak özellikle iki sınıf arasındaki ayrımı artırır. ReLU fonksiyonu, pozitif girdiler için doğrusal bir çıktı verirken negatif girdiler için sıfır çıktısı vererek derin ağların daha hızlı ve verimli öğrenmesini sağlar (Agrawal, 2013). Aktivasyon fonksiyonları, modelin öğrenme kapasitesini ve performansını doğrudan etkilediği için, doğru fonksiyonun seçimi modelin başarısı açısından kritik öneme sahiptir.



Şekil 2.1. Aktivasyon Fonksiyonları (Nwankpa vd., 2018)

3.2.5. Kayıp fonksiyonu

Kayıp fonksiyonu, derin öğrenme modellerinin eğitim sürecinde modelin performansını değerlendiren ve optimize eden kritik bir bileşendir. Kayıp fonksiyonu, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkı ölçerek bir hata metriği sağlar. Bu hata metriği, modelin tahminlerinin doğruluğunu yansıtır ve modelin ağırlıklarını güncellemek için kullanılan geri yayılım algoritması aracılığıyla optimize edilir. Tekrarlayan bir sinir ağı olması durumunda, tüm zaman dilimlerindeki L kayıp

fonksiyonu, her zaman dilimindeki kaybı temel alınarak aşağıdaki gibi tanımlanır: (Goodfellow, 2016)

$$L(\hat{y}, y) = \sum_{t=1}^{T_y} L(\hat{y}^{(t)}, y^{(t)}) \quad (3.7)$$

Bu formül, $\hat{y}$ (tahmin edilen değerler) ve y (gerçek değerler) arasındaki farkı hesaplayan bir kayıp fonksiyonudur. Her bir zaman adımı t için kayıp fonksiyonu $L(\hat{y}^{(t)}, y^{(t)})$ hesaplanır ve toplam kayıp, tüm zaman adımlarının toplamı olarak elde edilir (Szandala, 2021).

3.2.6. ADAM optimizasyonu

ADAM (Adaptive Moment Estimation) optimizasyon algoritması, derin öğrenme modellerinin eğitiminde yaygın olarak kullanılan, etkin ve güçlü bir optimizasyon yöntemidir. ADAM, hem momentum temelli SGD (Stochastic Gradient Descent) hem de RMSprop algoritmalarının avantajlarını birleştirir. İki ayrı öğrenme oranı parametresini (momentum ve ölçeklendirilmiş gradyan) kullanarak, her parametre için ayrı ayrı öğrenme oranlarını adaptif olarak ayarlar (Goodfellow, 2016). Bu algoritma, geçmiş gradyanların ortalamasını (momentum) ve bu gradyanların karesinin ortalamasını (ölçeklendirilmiş gradyan) hesaplayarak, öğrenme oranını daha istikrarlı ve hızlı hale getirir (Nielsen, 2019). ADAM, büyük veri kümeleri ve yüksek boyutlu parametre uzaylarıyla çalışırken özellikle etkilidir. Parametrelerin adaptif güncellenmesi sayesinde, ADAM genellikle hızlı yakınsama sağlar ve hiperparametre ayarına duyarlılığı azaltır.

3.3. Yapay Sinir Ağları ve Çalışma Prensipleri

ANN, biyolojik sinir ağlarından esinlenerek geliştirilmiş bilgi işlem sistemleridir. Bu ağlar, nöron adı verilen işlem birimlerinden oluşur ve bu nöronlar arasındaki bağlantılar aracılığıyla veri işleme süreçlerini gerçekleştirir (Sharma vd., 2020). Her nöron, belirli bir giriş setini alarak, bu girdileri belirli ağırlıklarla çarpar, bir özetleme fonksiyonu ve bir aktivasyon fonksiyonu uygular ve sonrasında bir çıktı üretir. Bu işlem, giriş verilerinden çıkış verilerine kadar bilgiyi işlerken, ağırlıkların optimize edilmesi (öğrenme) yoluyla modelin eğitilmesini sağlar (Nielsen, 2019). Yapay sinir ağlarının ileri beslemeli sinir ağı (Feedforward Neural Networks - FNN), evrişimli sinir ağları (Convolutional Neural Networks - CNN), yinelemeli sinir ağı (Recurrent Neural Networks - RNN), çekişmeli üretici ağı (Generative Adversarial Networks - GANs) gibi

çeşitli türleri mevcuttur. Bu ağlar, birçok farklı alanda olduğu gibi zaman serisi analizinde de yaygın olarak kullanılmaktadır.

ANN, giriş katmanı, gizli katmanlar ve çıkış katmanı olmak üzere farklı katmanlardan oluşur. Giriş katmanı, ham veriyi alarak, bu veriyi gizli katmanlara iletir. Gizli katmanlar, veriyi işleyerek, öğrenme sürecini gerçekleştirir ve son olarak çıkış katmanı, işlenen veriyi anlamlı sonuçlara dönüştürür (Sharma vd., 2020).

Yapay sinir ağlarının öğrenme süreci, genellikle geri yayılım (backpropagation) algoritması ile gerçekleştirilir. Bu algoritma, ağın çıktıları ile beklenen sonuçlar arasındaki hatayı hesaplayarak, bu hatayı minimize etmek amacıyla ağın ağırlıklarını günceller. Bu sayede, yapay sinir ağı, veri setindeki desenleri öğrenir ve yeni veriler üzerinde doğru tahminler yapabilir.

Zaman serisi analizi, ardışık zaman dilimlerinde ölçülen veri noktalarının incelenmesi ile ilgilenir ve bu süreçte yapay sinir ağlarının kullanımı, özellikle karmaşık ve doğrusal olmayan ilişkileri yakalamada oldukça etkilidir. Finans, hava durumu tahmini, enerji tüketimi ve satış tahminleri gibi birçok alanda zaman serisi verileri yaygın olarak kullanılmaktadır. Sinir ağları, bu tür verilerdeki desenleri ve eğilimleri öğrenmede güçlü araçlar olarak öne çıkar. Özellikle CNN ve RNN, zaman serisi analizinde sıklıkla tercih edilmektedir.


ANN ile zaman serisi analizi arasındaki ilişki, verilerin zamana bağlı değişimlerini öğrenme ve tahmin etme yeteneği üzerine kuruludur. Zaman serisi analizi, bir dizi zaman diliminde toplanan verilerin analiz edilmesini ve bu veriler üzerinden gelecekteki değerlerin tahmin edilmesini içerir. ANN, özellikle karmaşık ve doğrusal olmayan ilişkilere sahip veri setlerinde yüksek doğrulukla tahminler yapabilme yeteneği sayesinde, zaman serisi analizinde önemli bir rol oynamaktadır.

3.4. Tekrarlayan Sinir Ağları (Recurrent Neural Networks)

RNN, özellikle zaman serileri verileri, doğal dil işleme ve diğer türden sıralı veriler üzerinde çalışmalar yapmak için tasarlanmış bir sinir ağları türüdür. RNN'ler, bilgiyi ardışık bir şekilde işler ve bir önceki adımdan gelen bilgileri sonraki adımlarla ilişkilendirerek hafızada tutma yeteneğine sahiptir (Goodfellow, 2016).

RNN'lerin temel yapısı, her bir zaman diliminde girdi ve önceki durumdan gelen bilgileri alarak bir çıktı üretir ve sonraki durumun girdisi olarak bu bilgiyi aktarır. Bu,

RNN'lerin öğrenme sürecinde girdiler arasındaki uzun süreli bağımlılıkları modelleyebilmesini sağlar. Ancak, bu süreçte ortaya çıkan "uzun süreli bağımlılık problemi" nedeniyle, pratikte daha gelişmiş RNN yapıları olan ve GRU gibi modeller tercih edilmektedir (Goodfellow, 2016).



Şekil 2.2. RNN Mimarisi(Yenilmez ve Mugenzi, 2023)

Bu ilişkiler sayesinde, girdiler kısa vadeli hafızaya kaydedilir ve çıktılar veya tahminler bu bilgilere dayanarak düzeltilir. Kendi içinde dönen bir döngü şeklinde işleyen bu sistemler, çalışmada gösterilen örnek uygulamada olduğu gibi doğrusal bir ilerleme yerine geriye dönük bir biçimde ilerler. Şekil 2.2.'de örnek bir RNN mimarisi sunulmuştur. (Yenilmez ve Mugenzi, 2023)

RNN, LSTM ve GRU gibi sinir ağı modelleri ise zaman serisi analizi için kullanılan derin öğrenme modelleridir. Basit bir RNN modelinin eşitlikleri şu şekildedir:

$$[h_t = \sigma(W_{\{ih\}}x_t + W_{\{hh\}}h_{t-1} + b_h)]$$

$$[y_t = \sigma(W_{\{hy\}}h_t + b_y)] \quad (3.8)$$

h_t : Zaman adımı t için gizli durum vektörü. Bu, RNN'in belleğindeki mevcut durumu temsil eder.

x_t : Zaman adımı t için girdi vektörü. Bu, o anki zamansal bilgiyi temsil eder.

W_{ih} : Girdi vektörü x_t ile gizli durum h_t arasındaki bağlantıyı öğrenen ağırlık matrisi.

W_{hh} : Bir önceki zaman adımındaki gizli durum h_{t-1} ile mevcut zaman adımındaki gizli durum h_t arasındaki bağlantıyı öğrenen ağırlık matrisi.

b_h : Bias terimi, gizli durumun oluşumunu düzenleyen sabit bir terimdir.

W_{hy} : Gizli durum h_t ile çıkış y_t arasındaki bağlantıyı öğrenen ağırlık matrisi.

b_y : Bias terimi, çıkışın oluşumunu düzenleyen sabit bir terimdir.

σ : Aktivasyon fonksiyonu. Bu, gizli durumun ve çıkışın nonlinear bir dönüşüme tabi tutulmasını sağlar.

3.4.1. Uzun vadeli bellek (Long short-term memory (LSTM))

LSTM, RNN ağlarının kademeli yok olma problemine çözüm olarak tasarlanmış bir nöral sinir ağı yapısıdır (Farhad Mortezaipoor Shiri vd., 2023).

LSTM, Sepp Hochreiter ve Jürgen Schmidhuber tarafından 1997 yılında tanıtılmıştır (Hochreiter ve Schmidhuber, 1997). Temel RNN yapılarından farklı olarak, LSTM birimleri üç farklı kapıdan (gate) oluşur: unutma kapısı (forget gate), giriş kapısı (input gate) ve çıkış kapısı (output gate). Bu kapılar, hücre durumları üzerinde seçici bir şekilde bilgi akışını kontrol eder, böylece ağı gereksiz bilgileri unutmasına ve önemli bilgileri uzun süreli hafızada tutmasına olanak tanır (Oliver-Muncharaz, 2020).

LSTM (Uzun Kısa Süreli Bellek) modeli:

$$\begin{aligned}
 [i_t &= \sigma(W_{\{xi\}}x_t + W_{\{hi\}}h_{t-1} + W_{\{ci\}}c_{t-1} + b_i)] \\
 [f_t &= \sigma(W_{\{xf\}}x_t + W_{\{hf\}}h_{t-1} + W_{\{cf\}}c_{t-1} + b_f)] \\
 [c_t &= f_t \odot c_{t-1} + i_t \odot \tanh(W_{\{xc\}}x_t + W_{\{hc\}}h_{t-1} + b_c)] \\
 [o_t &= \sigma(W_{\{xo\}}x_t + W_{\{ho\}}h_{t-1} + W_{\{co\}}c_t + b_o)] \\
 [h_t &= o_t \odot \tanh(c_t)]
 \end{aligned} \tag{3.9}$$

c_t : Hücre durumu. Modelin uzun vadeli belleğini temsil eder.

o_t : Çıkış kapısı. Hücre durumunun ne kadarının kullanılacağını kontrol eder.

h_t : Gizli durum vektörü. LSTM'in anlık çıktısını temsil eder.

Ayrıca, diğer değişkenler ve terimlerin açıklamaları da şu şekildedir:

x_t : Zaman adımı t için girdi vektörü.

h_{t-1} : Bir önceki zaman adımındaki gizli durum vektörü.

c_{t-1} : Bir önceki zaman adımındaki hücre durumu.


$W_{xi}, W_{hi}, W_{ci}, W_{xf}, W_{hf}, W_{cf}, W_{xc}, W_{hc}, W_{xo}, W_{ho}, W_{co}$: Ağırlık matrisleri, girdi, gizli durum ve hücre durumu arasındaki ilişkileri öğrenir.

b_i, b_f, b_c, b_o : Bias terimleri.

σ : Sigmoid aktivasyon fonksiyonu.

$\tanh$: Hiperbolik tanjant aktivasyon fonksiyonu.

$\odot$: Eleman bazında (Hadamard) çarpma işlemi.



Şekil 2.3. LSTM mimarisi(Farhad MortezaPour Shiri vd., 2023)

Unutma kapısı, hücrenin önceki durumundan hangi bilgilerin silineceğini belirler. Bu kapı, geçmiş bilgilerin hücre durumundan ne kadarının korunacağını veya unutulacağını sigmoid fonksiyonu aracılığıyla ayarlar (Wen ve Li, 2023). Şekil 2.3.'te LSTM mimari örneği sunulmuştur (Farhad MortezaPour Shiri vd., 2023).

Giriş kapısı, mevcut girdi ile yeni aday değerlerin hücre durumuna eklenip eklenmeyeceğine karar verir. Bu süreç, sigmoid ve tanh fonksiyonlarının bir kombinasyonu ile yönetilir. Girdi kapısı, hücreye yeni bilgilerin eklenip eklenmeyeceğini

kontrol ederken, tanh fonksiyonu bu yeni bilgilerin nasıl bir değer alacağını belirler.(Staudemeyer ve Moris, 2019)

Çıkış kapısı, sonraki gizli durumun hangi bilgileri içereceğini belirler. Bu kapı, mevcut hücre durumunun bir sonraki gizli katmana ve çıktılara nasıl aktarılacağını kontrol eder.

3.4.2. Geçitli tekrarlayan birim (Gated recurrent unit (GRU))

Temel RNN'lerin sınırlamalarını aşmak için Long Short-Term Memory (LSTM) ağları ve Gated Recurrent Units (GRU'lar) gibi daha gelişmiş varyantlar geliştirilmiştir. GRU'lar, Cho ve arkadaşları tarafından 2014 yılında tanıtılmıştır ve basit yapıları ile LSTM'lere alternatif olarak popülerlik kazanmışlardır (Cho vd., 2014).

GRU'lar, LSTM'lerde olduğu gibi ayrı bellek hücreleri kullanmaksızın, farklı zaman ölçeklerindeki bağımlılıkları adaptif olarak yakalamak için tasarlanmıştır. Bir GRU hücresi, iki ana kapıdan oluşur: reset kapısı ve güncelleme kapısı (Goodfellow, 2016).

Reset Kapısı (r_t): Reset kapısı, önceki hafızanın ne kadarını unutacağını belirler. Reset kapısı 0'a yakın olduğunda, önceki durumu etkin bir şekilde unuttur.

Güncelleme Kapısı (z_t): Güncelleme kapısı, yeni hafıza içeriğinin ne kadarının önceki hafızaya eklenmesi gerektiğini kontrol eder. Bu kapı, birimin aktivasyonunu ne kadar güncelleyeceğini belirler.

GRU modeli:

$$\begin{aligned} [z_t &= \sigma(W_{\{xz\}}x_t + W_{\{hz\}}h_{\{t-1\}} + b_z)] \\ [r_t &= \sigma(W_{\{xr\}}x_t + W_{\{hr\}}h_{\{t-1\}} + b_r)] \\ [n_t &= \tanh(W_{\{xn\}}x_t + r_t \odot (W_{\{hn\}}h_{\{t-1\}}) + b_n)] \\ [h_t &= (1 - z_t) \odot n_t + z_t \odot h_{\{t-1\}}] \end{aligned} \quad (3.10)$$

z_t : Güncelleme vektörü. Ne kadar eski bilginin korunacağını kontrol eder.

r_t : Reset vektörü. Ne kadar eski bilginin unutulacağını kontrol eder.

z_t : Yeni durum vektörü adayı. Güncel girdi ve önceki gizli durumun birleşimiyle hesaplanır.

h_t : Güncellenmiş gizli durum vektörü. Sonraki adımda kullanılacak gizli durumu temsil eder.

x_t : Zaman adımı t için girdi vektörü.

h_{t-1} : Bir önceki zaman adımındaki gizli durum vektörü.

W_x, W_h, W_r, W_n, W_h : Ağırlık matrisleri, girdi ve gizli durum arasındaki ilişkileri öğrenir.


b_z, b_r, b_n : Bias terimleri.

σ : Sigmoid aktivasyon fonksiyonu.

$\odot$: Eleman bazında (Hadamard) çarpma işlemi.

Burada σ sigmoid aktivasyon fonksiyonunu, $\odot$ ise eleman bazlı çarpmayı temsil eder. W_r , W_z ve W sırasıyla reset kapısı, güncelleme kapısı ve aday aktivasyon için ağırlık matrisleridir (Goodfellow, 2016).

GRU modeli LSTM modeline göre daha basit bir mimariye sahip olmaları, daha az parametre kullanmalarına olanak tanır. Bu durum, GRU'ların daha hızlı eğitim yapabilmesini ve daha az hesaplama kaynağı tüketmesini sağlar. Bilgi ve gradyan akışını etkili bir şekilde yöneterek, GRU'lar kaybolan gradyan problemini azaltır ve daha uzun bağımlılıkları modelleyebilir. Kapı mekanizması, GRU'ların durumlarını adaptif olarak sıfırlamasına veya güncellemesine olanak tanır, bu da onları çeşitli sıralı görevler için esnek kılar (Seabe vd., 2023). Ayrıca, birçok görevde GRU'lar, daha basit yapısına rağmen LSTM'ler ile aynı performansı gösterebilir veya daha iyi performans sergileyebilir. Şekil 2.4.'te GRU mimarisi örneği sunulmuştur (Seabe vd., 2023).



Şekil 2.4. Geçitli tekrarlayan mimarisi (Qianmin vd., 2023)

3.5. Transformer Model

Transformer modeli, doğal dil işleme (NLP) alanında devrim yaratan ve günümüzde birçok modern dil modelinin temelini oluşturan bir sinir ağı mimarisidir. Bu model, dikkat (attention) mekanizmasını merkezine alarak sıralı veriler üzerinde işlem yapma şeklini değiştirmiştir (Vaswani vd., 2017). Geleneksel sıralı veri işleme yöntemlerinin aksine, Transformer modeli, verilerin tüm parçalarına paralel olarak dikkat eder ve bu sayede eğitim süresini önemli ölçüde hızlandırır ve uzun bağımlılıkları daha etkili bir şekilde yakalar (Vaswani vd., 2017).

Transformer modeli, encoder (kodlayıcı) ve decoder (çözücü) olmak üzere iki ana bileşenden oluşur. Hem encoder hem de decoder, çok katmanlı yapılar şeklinde düzenlenmiştir ve her katman, çoklu başlı dikkat (multi-head attention) ve beslemeli ileri ağ (feed-forward network) katmanlarından oluşur (Seabe vd., 2023).

- **Encoder:** Encoder, giriş dizisini alır ve her bir kelimenin bağlamını yakalamak için çoklu başlı dikkat katmanlarını kullanarak kodlar. Encoder'dan çıkan çıktı, decoder tarafından kullanılmak üzere bir dizi gizli durum vektörü oluşturur.
- **Decoder:** Decoder, encoder'dan gelen gizli durum vektörlerini kullanarak hedef diziyi (örneğin, çevrilecek cümleyi) oluşturur. Decoder, kendi çoklu başlı dikkat katmanlarını kullanarak hem giriş dizisine hem de kendi çıktısına dikkat eder.

Kodlayıcı (Encoder) Katmanı:

$$[Z^{(l)} = \text{LayerNorm}(X^{(l)} + \text{MultiHeadAttention}(X^{(l)}))]$$

$$[Z^{(l+1)} = \text{LayerNorm}(Z^{(l)} + \text{FeedForward}(Z^{(l)}))] \quad (3.11)$$

Burada;

$X^{(l)}$, l -inci encoder katmanına giren veriyi temsil eder. İlk encoder katmanı için ($l = 1$), $X^{(1)}$ girdi dizisinin gömülmüş hali ve pozisyonel kodlamanın toplamıdır (Vaswani vd., 2017).

$\text{MultiHeadAttention}(X^{(l)})$, girdiyi $X^{(l)}$ multi-head self-attention mekanizmasından geçirir. Bu mekanizma, giriş dizisindeki her bir token'ın diğer tüm token'lara göre dikkat skorlarını hesaplar. Multi-head attention mekanizması, paralel olarak çalışan birkaç dikkat başlığından oluşur ve her bir başlık kendi doğrusal dönüşümlerine (query (sorgu), key (anahtar) ve value (değer) projeksiyonları) sahiptir (Vaswani vd., 2017).

$\text{LayerNorm}(\cdot)$ katman normalizasyonu fonksiyonunu gösterir. Katman normalizasyonu, her bir eğitim örneği için girdileri özellikler boyunca normalleştirir. Bu, eğitim sürecini stabilize eder ve hızlandırır (Vaswani vd., 2017).

$\text{FeedForward}(Z^{(l)})$, multi-head attention mekanizmasından çıkan $Z^{(l)}$ değerini pozisyonel tam bağlı (feed-forward) sinir ağına gönderir. Genellikle iki doğrusal dönüşüm ve aralarında bir ReLU aktivasyon fonksiyonu bulunur. $Z^{(l)}$ ise multi-head attention mekanizmasından ve katman normalizasyonundan sonra oluşan ara çıktıdır (Vaswani vd., 2017).

Kod Çözücü (Decoder) Katmanı:

$$[Z_1^{(l)} = \text{LayerNorm}(X^{(l)} + \text{MultiHeadAttention}(X^{(l)}))]$$

$$[Z_2^{(l)} = \text{LayerNorm}(Z_1^{(l)} + \text{MultiHeadAttention}(Z_1^{(l)}))]$$

$$[Z^{\{(l+1)\}} = \text{LayerNorm}(Z_2^{(l)} + \text{FeedForward}(Z_2^{(l)}))] \quad (3.12)$$

Burada:

Kodlayıcı (Encoder) Katmanı:

$X^{(l)}$: Katman l için girdi vektörleri. Bu, kodlayıcı katmanın girdisini temsil eder.

$Z^{(l)}$: Katman l için çıktı vektörleri. Bu, kodlayıcı katmanın çıktısını temsil eder.

LayerNorm: Katman normalizasyonu işlemi. Bu, girdi vektörlerinin normalleştirilmesini sağlar.

MultiHeadAttention: Çoklu kafa dikkat mekanizması. Bu, farklı dikkat başlıklarını ve bunların birleşimini hesaplar.

FeedForward: İleri besleme (feedforward) ağı. Bu, ağı katmanları arasında nonlineer dönüşümleri gerçekleştirir.

Kod Çözücü (Decoder) Katmanı:


$X^{(l)}$: Katman l için girdi vektörleri. Bu, kod çözücü katmanının girdisini temsil eder.

$Z_1^{(l)}$: İlk dikkat katmanının çıktı vektörleri.

$Z_2^{(l)}$: İkinci dikkat katmanının çıktı vektörleri.

$Z^{(l+1)}$: Katman l için çıktı vektörleri. Bu, kod çözücü katmanının çıktısını temsil eder.

Transformer modelinin temel yeniliği olan dikkat mekanizması, modelin girdinin tüm parçalarına aynı anda dikkat etmesini sağlar ve bu sayede uzun menzilli bağımlılıkları daha etkili bir şekilde öğrenir. Dikkat mekanizması, bir sorgu (query), anahtar (key) ve değer (value) üçlüsü üzerinden çalışarak her kelimenin diğer kelimelerle olan ilişkisini belirler. Pozisyonel kodlama ise dizideki kelimelerin konum bilgilerini modelin öğrenebilmesi için giriş emebeding'lerine eklenen benzersiz vektörlerdir. Bu sayede model, kelimelerin sırasını öğrenebilir ve sıralı bilgileri işleyebilir. Şekil 6'te Transformer mimarisi için örnek sunulmuştur (Yang Li vd., 2024).



Şekil 2.5. Transformer mimarisi (Yang Li vd., 2024)

3.6. Çalışmada Kullanılan İstatistiksel Teknikler ve Seçim Kriterleri

3.6.1. Veri ölçeklendirme

Model performansını optimize etmek ve eğitim sürecini iyileştirmek için kritik bir adımdır. Özelliklerin farklı ölçeklerde olması, özellikle gradient descent tabanlı algoritmaların verimli öğrenmesini engelleyebilir. Örneğin, bir özelliğin değer aralığı 0 ile 1 arasında değişirken, bir diğerinin 1000 ile 10000 arasında değişmesi, yüksek değerli özelliklerin düşük değerli olanları baskılamasına neden olabilir (Erkal, 2021). Bu durum, modelin hatalı öğrenmesine ve sonuçların doğruluğunun düşmesine yol açar. Veri ölçeklendirme yöntemleri arasında en yaygın olarak kullanılanlar Min-Max ölçeklendirme ve Z-score standardizasyonudur. Min-Max ölçeklendirme, verileri 0 ile 1 arasında bir aralığa sıkıştırırken, Z-score standardizasyonu verileri ortalaması 0 ve standart sapması 1 olacak şekilde dönüştürür. Bu sayede, tüm özelliklerin aynı ölçekte olması sağlanır, modelin eğitim süreci hızlanır ve doğruluğu artar. Veri ölçeklendirme, modelin daha hızlı ve doğru bir şekilde öğrenmesini mümkün kılar ve genellikle ön işleme adımının vazgeçilmez bir parçası olarak kabul edilir.

3.6.2. Artık analizi(Residual analysis)

Artık analizi, bir modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkları (artıklar) inceleyerek modelin performansını değerlendiren bir tekniktir.

Artıkların analizi, modelin doğruluğunu, öngörü hatalarının yapısını ve belirli kalıplar veya sapmalar olup olmadığını ortaya çıkarmak için kullanılır. İyi bir modelde artıkların ortalamasının sıfıra yakın olması ve rastgele dağılması beklenir. Sistemik bir desen veya kalıp, modelin belirli bir yapıyı kaçırdığını veya modelin bazı varsayımlarının ihlal edildiğini gösterebilir (Fernandez,1992). Artık analizi, modelin iyileştirilmesi gereken alanları belirlemek ve modelin geçerliliğini sağlamak için önemli bir adımdır.

3.6.3. Augmented Dickey-Fuller(ADF) Testi

Augmented Dickey-Fuller (ADF) testi, bir zaman serisinin durağan olup olmadığını belirlemek için kullanılan istatistiksel bir testtir. Durağanlık, bir zaman serisinin ortalaması, varyansı ve otokorelasyon yapısının zaman içinde sabit kalması anlamına gelir ve zaman serisi analizlerinde önemli bir özelliktir. ADF testi, Dickey-Fuller testinin genişletilmiş bir versiyonudur ve serinin gecikmeli değerlerini de hesaba katarak daha güçlü ve güvenilir sonuçlar verir. Testin hipotezleri şunlardır: sıfır hipotezi (H_0), zaman serisinin birim köke sahip olduğunu ve durağan olmadığını belirtirken, alternatif hipotez (H_1), serinin durağan olduğunu belirtir. ADF testi, özellikle finansal zaman serileri ve ekonomik veriler gibi birim kök içerebilecek veri setlerinin analizinde yaygın olarak kullanılır.

3.6.4. Ortalama mutlak hata yüzdesi (MAPE)

Ortalama mutlak hata yüzdesi (MAPE), model tahminlerinin doğruluğunu ölçmek için kullanılan bir performans metriğidir (Goodwin ve Lawton, 1999). Gerçek değerler ile tahmin edilen değerler arasındaki farkların yüzde cinsinden ortalamasını alarak hesaplanır. MAPE, farklı birimlerdeki verilerle karşılaştırma yapmayı kolaylaştırır ve genellikle yüzde olarak ifade edilir. Düşük MAPE değerleri, modelin yüksek doğrulukla tahmin yaptığını gösterir. MAPE'nin hesaplanmasında, her bir gözlem için mutlak hata, gerçek değere bölünerek yüzdesi bulunur ve tüm bu yüzdelere ortalaması alınır. Bu metrik, özellikle zaman serisi tahminlerinde ve ekonomik analizlerde yaygın olarak kullanılır (Goodwin ve Lawton., 1999). MAPE'nin formülü şu şekildedir:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (3.13)$$

Burada y_i gerçek değer, $\hat{y}_i$ tahmin edilen değer ve n toplam gözlem sayısıdır.

3.6.5. Kök ortalama kare hatası (RMSE)

Kök ortalama kare hatası (RMSE), bir modelin tahminlerinin doğruluğunu değerlendirmek için kullanılan yaygın bir performans metriğidir. RMSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasının karekökü alınarak hesaplanır (Hodson, 2022). Bu metrik, hataların büyüklüğünü korur ve daha büyük hataları daha fazla cezalandırır, bu yüzden modelin büyük hatalara karşı ne kadar duyarlı olduğunu gösterir. RMSE birimi, tahmin edilen değişkenin birimiyle aynıdır ve düşük RMSE değerleri, modelin yüksek doğrulukla tahmin yaptığını gösterir. RMSE'nin hesaplanması, hataların karelerinin ortalamasının alınması ve ardından bu ortalamanın karekökünün alınması şeklindedir. Bu metrik, özellikle regresyon analizlerinde ve zaman serisi tahminlerinde sıkça kullanılır (Hodson, 2022)..

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.14)$$

y_i gerçek değer, $\hat{y}$ tahmin edilen değer ve n toplam gözlem sayısıdır.

3.6.6. R-kare (R^2)

R-Kare (R^2), bir regresyon modelinin açıklayıcılığını değerlendiren istatistiksel bir ölçüttür. R^2 , bağımsız değişkenlerin bağımlı değişkendeki toplam varyansın ne kadarını açıkladığını gösterir ve 0 ile 1 arasında bir değer alır. 1'e yakın R^2 değerleri, modelin yüksek bir doğrulukla veri noktalarını açıkladığını ve bağımsız değişkenlerin bağımlı değişken üzerindeki etkisinin güçlü olduğunu gösterir. (Eubank, 1999)

$$R^2 = \left[1 - \frac{KT_{HT}}{KT_{TOP}} \right] \quad (3.15)$$

Burada:

KT_{HT} , modelin açıklayamadığı toplam sapma miktarını ifade eder.

KT_{TOP} , veri noktalarının ortalamadan toplam sapmasını ifade eder.

4. ANALİZ

Bu çalışmada RNN, LSTM ve GRU yöntemlerinden yararlanılarak zaman serisi analizinde özellikle RNN ve önemli türleri ile Transformer modelinin performansı ele alınmıştır. Böylece bu yöntemlerin zaman serisi analizinde kullanımı konusunda kapsayıcı bir analiz sunulması hedeflenmiştir. İmputasyon teknikleri kullanılarak eksik veriler tamamlanmış ve bu sayede veri setinin bütünlüğü sağlanmış olup imputasyon yöntemlerinin performansı analiz edilmiştir. Veri üretim süreci tekrarlı yapıda oluşturulmuştur. Simülasyon çalışması bu çerçevede yürütülmüştür (Atmaca ve Yenilmez, 2024). Ayrıca gerçek veriler ile uygulamalar yapılmış olup üç farklı hisse senedinin kapanış fiyatlarından yararlanılmıştır.

4.1. Simülasyon

Bu bölümde, sentetik veri setini simüle etmek amacıyla LSTM, RNN, GRU ve Transformer Model yöntemleri ve elde edilen sonuçlar detaylı bir şekilde ele alınmaktadır. Simülasyon, hisse senedi fiyatlarının belirli bir trend, mevsimsellik ve rastgele gürültü bileşenlerine dayanarak nasıl hareket ettiğini göstermeyi amaçlamaktadır.

Bu bölümde, 2006-2024 yılları arasında 6.500 birimlik bir sentetik veri üretilmiştir. Rastgelelik unsurlarının tutarlılığını sağlamak ve tekrar edilebilir sonuçlar elde etmek için numpy ve tensorflow kütüphanelerinin rastgelelik tohumları ayarlanmıştır. Hisse senedi fiyatlarının genel eğilimi, ilk önce başlangıç fiyatı 50 TL'den başlayıp 150 TL'ye ulaşan bir lineer trend ile modellenmiştir. Daha sonra veriye zaman serisi yapısı kazandırmak için aşağıdaki prosedür uygulanmıştır. Günlük fiyat değişimlerinde rastgele gürültü oluşturmak için normal dağılıma sahip rastgele değişkenler kullanılmıştır. Bu, hisse senedi fiyatlarının günlük küçük dalgalanmalarını temsil eder. Ayrıca, veri setine mevsimsel bileşen olarak 10 birim genliğinde bir sinüs dalgası eklenmiştir. Bu, yıllık döngüleri ve hisse senedinin yıl içindeki düzenli dalgalanmalarını yansıtır. Simülasyonun gerçekçiliğini artırmak amacıyla, rastgele seçilen zaman dilimlerine yüksek volatilité içeren aykırı değerler eklenmiştir. Bu, beklenmedik piyasa olayları veya haberlerin hisse fiyatlarına etkisini temsil eder. Rastgele seçilen dört noktada hisse fiyatları üzerinde yukarı veya aşağı doğru uzun vadeli trend değişiklikleri simüle edilmiştir. Veri setinde, trend değişiklikleri de bulunmaktadır;

bu, belirli aralıklarla (örneğin her 500 günde bir) fiyat trendinin ani ve kalıcı değişiklikler göstermesi ile modellenmiştir. Son olarak, tüm bu bileşenler birleştirilmiş ve günlük getirilerin kümülatif etkisi ile hisse senedi fiyatları oluşturulmuştur. Öte yandan, otoregresif (AR) ve hareketli ortalama (MA) etkileri de modele dahil edilmiştir. Otoregresif (AR) etkiler, önceki günlerin fiyatlarının bugünkü fiyatı etkilemesi şeklinde modellenmiştir, bu da zaman serisinin kendi geçmiş değerleriyle olan ilişkisini yansıtır. Hareketli ortalama (MA) etkileri ise, önceki günlerin hata terimlerinin bugünkü fiyat üzerindeki etkisini içerir, bu da fiyat serisindeki gürültü ve ani değişimlerin yumuşatılmasını sağlar.

4.2. Uygulama

Bu çalışmada, ML modellemesi için Python dili tercih edilmiştir. Veri setlerinin hazırlanması ve çıktıların tablo ve grafik olarak sunulmasında ise Microsoft Excel programından yararlanılmıştır. Bu çalışmada, farklı zaman serisi tahmin modellerinin (RNN, LSTM, GRU ve Transformer modelleri) çeşitli veri tamamlanma (imputasyon) teknikleri altında performansları değerlendirilmiştir. Modeller, lineer, spline, Stineman, ortalama ve rasgele imputasyon yöntemleri kullanılarak ve tam veri, %5, %15, %25 oranlarında eksik verilerle test edilmiştir. Verilerin eksiltilmesinde rassallığa dayalı bir prosedür uygulanmıştır (Yenilmez ve Kantar, 2023).

EPOCH, ML ve derin öğrenme eğitim süreçlerinde yaygın olarak kullanılan bir terimdir. Bir epoch, modelin tüm eğitim veri kümesi üzerinde bir kez tam olarak eğitilmesi anlamına gelir. Bu süreç, genellikle şu adımlarla gerçekleşir:

Veri bölme, eğitim veri kümesinin genellikle küçük parçalara veya mini-batch'lere bölünmesi sürecini ifade eder. Bu işlem, modelin daha verimli bir şekilde eğitilmesini sağlar ve bellekte yer sorunlarını minimize eder. İleri yayılım (forward propagation) aşamasında model, mini-batch'teki her veri örneği için tahminlerde bulunur ve tahminlerle gerçek değerler arasındaki fark (hata) hesaplanır. Geri yayılım (backward propagation) sürecinde ise bu hatalar, modelin ağırlıklarını ve biaslarını güncellemek için kullanılır. Geri yayılım sırasında hesaplanan gradyanlara dayanarak ağırlıklar ve biaslar güncellenir ve bu süreç, modelin performansını sürekli olarak iyileştirir.

Epoch tamamlanması, modelin eğitim veri kümesindeki tüm mini-batch'leri tamamlaması anlamına gelir. Uygun epoch sayısını belirlemek, makine öğrenimi ve derin

öğrenme modellerinin eğitiminde önemli bir adımdır ve bu sayı modelden modele, veri kümesinden veri kümesine farklılık gösterir. Modelin yeterince öğrenmesini sağlamak ve aşırı öğrenmeyi (overfitting) önlemek açısından uygun epoch sayısının belirlenmesi kritik bir dengedir. Modeli eğitirken hem eğitim kaybını (training loss) hem de doğrulama kaybını (validation loss) izlemek önemlidir. Eğitim kaybı sürekli azalırken, doğrulama kaybı bir noktada azalmayı durdurup artmaya başlayabilir, bu nokta modelinizin aşırı öğrenmeye başladığını gösterir. Eğitim ve doğrulama kayıplarının izlenmesi, uygun epoch sayısını belirlemek için en yaygın kullanılan yöntemlerden biridir.

Erken durdurma (early stopping); doğrulama kaybı belirli bir epoch sayısı boyunca iyileşmediğinde eğitimi durduran bir tekniktir. Bu yöntem, modelin aşırı öğrenmesini önleyerek uygun epoch sayısını otomatik olarak belirler. Örneğin, doğrulama kaybı 10 epoch boyunca iyileşmezse eğitim durdurulabilir. Ayrıca, veriyi farklı parçalara bölerek modelin performansını çapraz doğrulama (cross-validation) ile değerlendirmek de uygun epoch sayısını belirlemede yardımcı olabilir. Farklı epoch sayıları deneyerek ve modelin performansını karşılaştırarak en uygun epoch sayısını belirlemek mümkündür. Epoch sayısı olarak 100 seçilmiş ve erken durdurma fonksiyonu 10 epoch olarak tanımlanmış olup, bu süreçte farklı epoch sayıları denenmiş ve modelin performansı karşılaştırılarak en uygun epoch sayısı belirlenmiştir.

4.3. Zaman Serisi Veri Seti İçin Derin Öğrenme Modellerinin Mimarisi ve Parametreleri

Bu çalışmada, çeşitli derin öğrenme modellerinin farklı veri doldurma yöntemleri altında nasıl performans gösterdiğini göstermektedir. RNN, LSTM, GRU ve Transformer modellerinin performansları incelenmiştir.

Çalışmada kullanılan veri seti, Borsa İstanbul'da işlem gören THYAO.IS (Türk Hava Yolları), Almanya'nın önde gelen havayolu şirketi Lufthansa'nın (LHA.DE) hisse senedi ile Amerika Birleşik Devletlerinin öncü hava yolu şirketlerinden Delta Hava Yolları (DAL) hisse senedine ait günlük kapanış fiyatlarından oluşmaktadır.

Derin öğrenme yöntemlerinin finansal zaman serisi tahminlerindeki etkinliğini incelemek amacıyla Türk Hava Yolları'nın, Delta Hava Yolları ve Lufthansa'nın günlük kapanış fiyatları kullanılarak bir model geliştirilmiştir. İlk olarak, yfinance kütüphanesi aracılığıyla 2006-2024 yılları arasındaki günlük kapanış fiyat verileri indirilmiş ve veri

setine %5, %15 ve %25 oranında rastgele eksik değerler oluşturulmuştur. Eksik veriler, lineer, Spline ve Stineman interpolasyon, ortalama ve rasgele sayılar yöntemi ile doldurulmuştur. Zaman serisi verisi uygun şekilde şekillendirildikten sonra, veri eğitim ve test setlerine ayrılmıştır. Eğitim verisi oranı %70 ve test veri seti %30 olarak ayarlanmıştır. Derin öğrenme modeli olarak, LSTM, RNN, GRU ve Transformer model tabanlı bir model kurulmuş ve modelin eğitimi sırasında erken durdurma yöntemi ile optimize edilmiştir.

Derin öğrenme tekniklerinden GRU, LSTM ve RNN yöntemleri ile modellemeler yapılmıştır. Her üç model de aynı yapıdadır ve her biri üç katmandan oluşmaktadır. İlk iki katman, her bir modelin belirli türüne (GRU, LSTM veya RNN) özgü katmanlardır ve her birinde 50 birim (nöron) bulunmaktadır. Katmanlar arası aktarım sağlanmış ve tam bağlı (dense) katman ile nihai çıktılar üretilmiştir. Bu genel yapı, hem GRU, LSTM hemde RNN modelleri için aynıdır ve bu sayede modellerin performanslarının doğrudan karşılaştırılabilir olması sağlanmıştır.

Çalışmada kullanılan bir diğer Transformer Modeli toplam sekiz katmandan oluşmaktadır. Modelin yapısında bir girdi katmanı, dört transformer encoder bloğu, bir global average pooling katmanı, bir Dense katmanı (MLP katmanı) ve bir çıktı katmanı bulunmaktadır. Girdi katmanı, zaman adımları ve özellik sayısı şeklinde yapılandırılmıştır.

4.4. Model Performans Karşılaştırmaları ve Yorum

4.4.1. Simulasyon ile sentetik veri uygulaması

Bu çalışmada, sentetik veri seti üzerinde farklı zaman serisi tahmin modellerinin (RNN, LSTM, GRU ve Transformer modelleri) çeşitli imputasyon teknikleri altında performansları incelenmiştir. Modeller, lineer, Spline, Stineman, ortalama ve rasgele imputasyon yöntemleri kullanılarak ve tam veri, %5, %15, %25 oranlarında eksik verilerle test edilmiştir. Tablo 4.1.'de sentetik veri setine ilişkin tanımlayıcı istatistiklere yer verilmiştir.

Tablo 4.1. Sentetik veri seti için tanımlayıcı istatistikler

Yapay Veri Seti - Tanımlayıcı İstatistikler	Gözlem Sayısı	Ortalama	Standart Sapma	Minimum	25%'lik Değer	50%'lik Değer	75%'lik Değer	Maksimum
	6.500	143,28	38,86	64,15	107,82	139,32	180,55	211,56

Tablo 4.1.'de sentetik veri setine ilişkin tanımlayıcı istatistikler incelendiğinde, veri seti 6.500 birimlik örneklemden oluşmakta olup ortalaması 143,28 ve standart sapma değeri ise 38,86'dır.

Sentetik veri setine ilişkin analiz sonuçları ise Tablo 4.2.'de paylaşılmıştır.

Tablo 4.2. *Sentetik veri seti için analiz sonuçları*

SENTETİK VERİ		LİNEER İMPUTASYON				SPLINE İMPUTASYON		
		0%	5%	15%	25%	5%	15%	25%
RNN	MAPE	0,9	1,24	1,27	1,6	1,12	1,16	1,84
	R ²	0,98	0,99	0,99	0,99	0,99	0,99	0,99
	RMSE	0,57	1,61	1,73	2,02	1,45	1,51	2,4
LSTM	MAPE	0,85	1,79	1,83	1,91	1,6	1,64	1,66
	R ²	0,98	0,99	0,99	0,98	0,98	0,98	0,98
	RMSE	0,53	2,3	2,33	2,42	2,1	2,12	2,13
GRU	MAPE	0,86	0,91	0,94	0,99	0,9	0,91	1,1
	R ²	0,98	0,99	0,99	0,99	0,99	0,99	0,99
	RMSE	0,53	1,19	1,24	1,31	1,15	1,18	1,45
TRANSFORMER MODELS	MAPE	0,15	0,17	0,21	0,27	0,19	0,2	0,22
	R ²	0,99	0,99	0,99	0,99	0,99	0,99	0,98
	RMSE	1,76	1,96	2,13	2,5	1,96	2,01	2,48


Tablo 4.2.(Devam) *Sentetik veri için analiz sonuçları*

SENTETİK VERİ		STINEMAN İMPUTASYON			ORTALAMA İMPUTASYON		
		0,05	0,15	0,25	5%	15%	25%
RNN	MAPE	1,01	1,1	1,63	4,24	5,09	13,62
	R ²	0,99	0,99	0,99	0,81	0,77	0,26
	RMSE	1,31	1,45	2,09	9,24	10,19	19,95
LSTM	MAPE	1,42	1,52	1,81	4,65	3,59	10,13
	R ²	0,99	0,99	0,98	0,82	0,83	0,4
	RMSE	1,91	1,97	2,32	8,91	8,71	17,99
GRU	MAPE	0,88	0,9	0,96	3,74	3,55	13,12
	R ²	0,99	0,99	0,99	0,82	0,83	0,39
	RMSE	1,15	1,17	1,23	8,82	8,73	18,11
TRANSFORMER MODELS	MAPE	0,18	0,19	0,21	8,9	3,13	10,66
	R ²	0,99	0,99	0,99	0,5	0,6	0,45
	RMSE	1,98	2,07	2,13	6,1	2,6	6,9


Tablo 4.2.(Devam) Sentetik veri için analiz sonuçları

SENTETİK VERİ		RASGELE İMPUTASYON		
		5%	15%	25%
RNN	MAPE	5,83	11,92	28,67
	R ²	0,7	0,32	0,24
	RMSE	12,4	22,43	33,92
LSTM	MAPE	4,29	10,15	12,12
	R ²	0,73	0,35	0,22
	RMSE	11,65	21,95	26,72
GRU	MAPE	4,31	11,08	14,91
	R ²	0,73	0,33	0,23
	RMSE	11,71	22,21	26,53
TRANSFORMER MODELS	MAPE	4,1	10,9	16,1
	R ²	0,41	0,38	0,22
	RMSE	3,6	8,6	10,14


Görsel 4.1.-4.4. ile modellemelere ilişkin tahmin grafikleri sunulmuştur. Görsellerdeki yeşil çizgi eğitim grafiklerini, mavi çizgi gerçek değerleri, kırmızı çizgi ise tahmin değerlerini temsil etmektedir.




Görsel 4.1. Yapay hisse senedi RNN modellemesine ilişkin tahmin grafiği



Görsel 4.2. Yapay hisse senedi LSTM modellemesine ilişkin tahmin grafiği



Görsel 4.3. Yapay hisse senedi GRU modellemesine ilişkin tahmin grafiği



Görsel 4.4. *Yapay hisse senedi Transformer modellemesine ilişkin tahmin grafiği*

Tahmin yöntemlerinin karşılaştırılmasına RNN modeliyle başlanmıştır. MAPE kriterine göre Stineman ve Spline imputasyon altında RNN modeli 1,01 – 1,84 arasında düşük değerler sunarken, rasgele imputasyon altında %5,83 - %28,67 arasında yüksek hatalar vermektedir. R^2 kriterine göre RNN modeli Stineman ve Spline imputasyon ile genelde 0,99 gibi yüksek değerler alırken, rasgele imputasyonda 0,24'e kadar düşen değerler vermektedir. RMSE kriterine göre RNN modeli Stineman ve Spline imputasyon ile genelde düşük değerler alınırken (1,31 – 1,45), rasgele imputasyonda oldukça yüksek değerler sunmaktadır (12,4 – 33,92).


MAPE kriterine göre LSTM modeli Stineman ve Spline imputasyon ile %1,42 - %1,81 arasında düşük değerler alırken, rasgele imputasyon ile %3,59 - %12,12 arasında yüksek hatalar sunmaktadır. R^2 kriterine göre LSTM modeli lineer ve spline imputasyon ile 0,99 gibi yüksek değerler alırken, rasgele imputasyonda 0,22'ye kadar düşüş göstermiştir. RMSE kriterine göre LSTM modeli Stineman ve Spline imputasyon ile 1,91 – 2,1 arasında düşük değerler alırken, rasgele imputasyon için 8,71 – 26,72 arasında yüksek değerler sunmaktadır.

MAPE kriterine göre GRU modeli Stineman ve Spline imputasyon ile %0,88 - %0,9 arasında düşük değerler alırken, rasgele imputasyon ile %3,55 - %14,91 arasında yüksek hatalar sunmaktadır. R^2 kriterine göre GRU modeli Stineman ve Spline imputasyon ile 0,99 gibi yüksek değerler alırken, rasgele imputasyonda 0,23'e kadar düşüş göstermektedir. RMSE kriterine göre GRU modeli Stineman ve Spline imputasyon ile

1,15 – 1,45 arasında düşük değerler alırken, rasgele imputasyonda 8,73 – 26,53 arasında yüksek değerler göstermektedir.

MAPE kriterine göre transformer modeli Stineman ve Spline imputasyon ile %0,18 - %0,22 arasında değişen düşük ve orta düzeyde değerler alırken, random imputasyon ile %3,13 - %16,1 arasında yüksek hatalar vermektedir. R^2 kriterine göre transformer modeli lineer ve spline imputasyon ile 0,98 – 0,99 gibi yüksek değerler alırken, random imputasyonda 0,22'ye kadar düşüş sunmaktadır. RMSE kriterine göre transformer modeli Stineman ve Spline imputasyon ile 1,96 – 2,48 arasında düşük değerler alırken, rasgele imputasyonda 2,6 – 10,14 arasında yüksek değerler göstermektedir.

Stineman imputasyon, RNN, LSTM, GRU ve Transformer modelleri için genelde düşük MAPE, yüksek R^2 ve düşük RMSE değerleri sağlamıştır. Görsel 4.5.'te %25 eksik veri durumunda Stineman imputasyon kullanıldığında Transformer modele ilişkin grafiğe yer verilmiştir.



Görsel 4.5. Yapay hisse senedi %25 eksik veri ve Stineman imputasyon ile Transformer modellemesine ilişkin tahmin grafiği

Spline imputasyon, Stineman imputasyon ile benzer şekilde, RNN, LSTM, GRU ve Transformer modelleri için düşük MAPE, yüksek R^2 ve düşük RMSE değerleri sağlamıştır.

Lineer imputasyon, performans genel olarak Stineman ve Spline imputasyon kadar iyi olmamış, ancak yine de nispeten daha tutarlı sonuçlar vermiştir.

Ortalama imputasyon, rasgele imputasyona göre daha iyi performans sergilemiş, ancak Stineman ve Spline imputasyon kadar başarılı olmamıştır.

Rasgele imputasyon, tüm modellerde en kötü performansı göstermiştir. MAPE değerleri çok yüksek, R^2 değerleri çok düşük ve RMSE değerleri çok yüksektir.

Sonuç olarak, en iyi tahmin yöntem olarak Transformer modeli en düşük hata oranlarına (MAPE) ve en yüksek doğruluk oranlarına (R^2) sahip olmuştur. En iyi imputasyon tekniği olarak Stineman ve Spline imputasyon, özellikle derin öğrenme modelleri (RNN, LSTM, GRU, Transformer) için en iyi performansı sağlamıştır. En kötü durumlar olarak rasgele imputasyon kullanıldığında tüm modellerde performans ciddi şekilde düşmüştür.

Öte yandan Transformer modelinin tahminleri, hemen hemen her dönem için uyumlu bir şekilde ilerlemektedir. Modelin eğitildiği veri setine dayalı olarak, gelecekteki kapanış fiyatları iyi bir şekilde tahmin edebildiğini göstermektedir.

Tüm modeller ve imputasyon teknikleri incelendiğinde ise Transformer modelin, Stineman imputasyon yöntemiyle olan kombinasyonları, zaman serisi tahminlerinde eksik veri sorunuyla başa çıkmak için en etkili yaklaşım olarak öne çıkmaktadır. Ek olarak rasgele imputasyon yönteminin diğer yöntemlere göre performansı oldukça düşük seviyede kalmıştır.

4.4.2. THYAO hisse senedi için uygulama

Bu çalışmada, çeşitli derin öğrenme modellerinin farklı veri doldurma yöntemleri altında nasıl performans gösterdiğini göstermektedir. RNN, LSTM, GRU ve Transformer modellerinin performansları incelenmiştir. THYAO hisse senedine ilişkin tanımlayıcı istatistikler Tablo 4.3.'te paylaşılmıştır.

Tablo 4.3. THYAO hisse senedi için tanımlayıcı istatistikler

THYAO - Tanımlayıcı İstatistikler	Gözlem Sayısı	Ortalama	Standart Sapma	Minimum	25%'lik Değer	50%'lik Değer	75%'lik Değer	Maksimum
	4.624	19,59	45,32	0,48	2,41	6,79	12,72	268,5

Tablo 4.3.'te THYAO hisse senedine ilişkin tanımlayıcı istatistikler incelendiğinde, veri seti 4.624 birimlik örneklemden oluşmakta olup ortalaması 19,59 ve standart sapma değeri ise 45,32'dir.

THYAO hisse senedine ilişkin analiz sonuçları ise Tablo 4.4'te paylaşılmıştır.

Tablo 4.4. THYAO hisse senedi için analiz sonuçları

THYAO			LİNEER İMPUTASYON				SPLINE İMPUTASYON		
		0%	5%	15%	25%	5%	15%	25%	
RNN	MAPE	2,71	7,18	8,24	10,09	6,11	7,85	9,52	
	R^2	0,99	0,94	0,9	0,87	0,95	0,95	0,92	
	RMSE	3,64	17,41	21,38	25,74	14,04	15,48	17,91	
LSTM	MAPE	3,24	4,1	4,4	4,44	2,86	3,41	3,95	
	R^2	0,99	0,99	0,99	0,99	0,99	0,99	0,99	
	RMSE	3,77	4,74	6,09	6,78	3,35	3,98	4,02	
GRU	MAPE	2,05	2,52	2,75	2,94	2,45	2,55	2,72	
	R^2	0,99	0,99	0,99	0,99	0,99	0,99	0,99	
	RMSE	2,71	3,12	3,19	3,36	3,08	3,6	3,82	
TRANSFORMER MODELS	MAPE	0,41	0,68	1,08	1,43	0,46	0,47	0,54	
	R^2	0,99	0,99	0,98	0,98	0,99	0,99	0,99	
	RMSE	2,25	2,43	2,58	4,38	2,41	2,47	3,34	


Tablo 4.4.(Devam) THYAO hisse senedi için analiz sonuçları

THYAO		STINEMAN İMPUTASYON			ORTALAMA İMPUTASYON		
		0,05	0,15	0,25	5%	15%	25%
RNN	MAPE	6,35	7,86	12,55	24,3	52,82	34,52
	R ²	0,94	0,93	0,81	0,51	0,28	0,16
	RMSE	17,01	17,72	31,37	48,96	57,53	59,13
LSTM	MAPE	2,92	3,47	4,6	24,61	33,54	42,84
	R ²	0,99	0,99	0,99	0,69	0,7	0,51
	RMSE	5,18	6,23	5,8	38,6	36,79	45,17
GRU	MAPE	2,65	2,82	2,98	24,42	39,76	48,62
	R ²	0,99	0,99	0,98	0,89	0,72	0,66
	RMSE	4,35	4,62	4,78	23,21	35,6	37,57
TRANSFORMER MODELS	MAPE	0,44	0,5	0,58	25,47	49,42	57,53
	R ²	0,99	0,99	0,99	0,86	0,66	0,45
	RMSE	2,45	2,58	3,88	28,76	43,65	54,36

Tablo 4.4.(Devam) THYAO hisse senedi için analiz sonuçları

THYAO - EPOCHS100		RASGELE İMPUTASYON		
		5%	15%	25%
RNN	MAPE	46,83	96,7	176,24
	R^2	0,43	0,31	0,11
	RMSE	89,17	87,53	84,14
LSTM	MAPE	49,74	81,76	122
	R^2	0,35	0,26	0,22
	RMSE	85,57	86,04	88,21
GRU	MAPE	36,46	79,11	130,58
	R^2	0,1	0,24	0,21
	RMSE	75,27	85,09	87,71
TRANSFORMER MODELS	MAPE	94,03	122,6	179,7
	R^2	0,51	0,22	0,22
	RMSE	55,59	84,75	85,42


Görsel 4.6.-4.9. ile modellemelere ilişkin tahmin grafikleri sunulmuştur. Görsellerdeki yeşil çizgi eğitim grafiklerini, mavi çizgi gerçek değerleri, kırmızı çizgi ise tahmin değerlerini temsil etmektedir.




Görsel 4.6. THYAO RNN modellemesine ilişkin tahmin grafiği



Görsel 4.7. *THYAO LSTM modellemesine ilişkin tahmin grafiği*



Görsel 4.8. *THYAO GRU modellemesine ilişkin tahmin grafiği*



Görsel 4.9. *THYAO Transformer modellemesine ilişkin tahmin grafiği*

Tahmin yöntemlerinin karşılaştırılmasına RNN modeliyle başlanmıştır. MAPE kriterine göre RNN modeli Stineman ve Spline imputasyon altında %6,11 -12,55 arasında düşük değerler sunarken, rasgele imputasyon altında %46,6 - %176,24 arasında yüksek hatalar vermektedir. R^2 kriterine göre RNN modeli Stineman imputasyon ve Spline imputasyonda genelde 0,9 üzeri değerler alırken, rasgele imputasyonda 0,43 gibi düşük değerler sunmaktadır. RMSE kriterine göre RNN modeli Spline imputasyon ile genelde 14,04 – 17,91 arası düşük değerler alınırken, rasgele imputasyonda 84,14 – 89,19 arasında oldukça yüksek değerler gözlenmiştir.

MAPE kriterine göre LSTM modeli Spline ve Stineman imputasyonda genelde 2,86 – 4,6 arasında düşük değerler alırken, rasgele imputasyonda değerler %24,61 - %122 arasında ciddi şekilde yükselmektedir. R^2 kriterine göre LSTM modeli Spline ve Stineman imputasyonda 0,99 gibi yüksek değerler alırken, rasgele imputasyonda 0,26'ya kadar düşüş gözlenmiştir. RMSE kriterine göre LSTM modeli Spline ve Stineman imputasyonda 3,35 – 6,23 arasında düşük değerler alırken, rasgele imputasyonda değerler 36,79 – 88,21 arasında ciddi şekilde artmaktadır.


MAPE kriterine göre GRU modeli Spline ve Stineman imputasyonda 2,45 – 2,98 arasında değişen düşük değerler alırken, rasgele imputasyonda %24,42 - %130,58 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre GRU modeli Spline ve Stineman imputasyonda 0,99 gibi yüksek değerler alınırken, rasgele imputasyonda 0,24'e kadar düşüş gözlenmiştir. RMSE kriterine göre GRU modeli Spline ve Stineman imputasyonda

3,08 – 4,78 arasında düşük değerler alırken, rasgele imputasyonda 35,6 – 87,71 arasında yüksek değerler gözlenmiştir.

MAPE kriterine göre transformer modeli Spline ve Stineman imputasyonda %0,46 - %0,58 arasında düşük değerler alırken, rasgele imputasyonda %25,47 - %179,7 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre transformer modeli Spline ve Stineman imputasyonda 0,99 gibi yüksek değerler alınırken, rasgele imputasyonda 0,22'ye kadar düşüş gözlenmiştir. RMSE kriterine göre transformer modeli Spline ve Stineman imputasyonda 2,41- 3,88 arasında düşük değerler alırken, rasgele imputasyonda 28,76 – 85,42 arasında yüksek değerler gözlenmiştir.

Lineer imputasyon, RNN, LSTM, GRU ve Transformer modelleri için genelde düşük MAPE, yüksek R^2 ve düşük RMSE değerleri sağlamıştır.

Spline imputasyon, Transformer modeli için en düşük MAPE, en yüksek R^2 ve en düşük RMSE değerleri sağlamıştır. Görsel 4.10.'da %25 eksik veri durumunda Spline imputasyon kullanıldığında Transformer modele ilişkin grafiğe yer verilmiştir.



Görsel 4.10. THYAO hisse senedi %25 eksik veri ve Spline imputasyon ile Transformer modellemesine ilişkin tahmin grafiği

Stineman imputasyon, genelde düşük MAPE, yüksek R^2 ve düşük RMSE değerleri sağlamıştır ve genel olarak tutarlı sonuçlar vermiştir.

Ortalama imputasyon, rasgele imputasyona göre daha iyi performans sergilemiş, ancak Spline ve Stineman imputasyon kadar başarılı olmamıştır.

Rasgele imputasyon, tüm modellerde en kötü performansı göstermiştir. MAPE değerleri çok yüksek, R^2 değerleri çok düşük ve RMSE değerleri oldukça yüksektir.

Sonuç olarak, en iyi tahmin yöntem Transformer model, Spline ve Stineman imputasyon kullanıldığında en düşük hata oranlarına (MAPE) ve en yüksek doğruluk oranlarına (R^2) sahip olmuştur. En iyi imputasyon tekniği olarak Spline imputasyon, özellikle derin öğrenme modelleri (RNN, LSTM, GRU, Transformer) için en iyi performansı sağlamıştır. En kötü durumlar olarak rasgele imputasyon kullanıldığında tüm modellerde performans ciddi şekilde düşmüştür.

Tüm modeller ve imputasyon teknikleri incelendiğinde ise Transformer modeli, Spline imputasyon yöntemiyle olan kombinasyonları, zaman serisi tahminlerinde eksik veri sorunuyla başa çıkmak için en etkili yaklaşım olarak öne çıkmaktadır. Ek olarak rasgele imputasyon yönteminin diğer yöntemlere göre performansı oldukça düşük seviyede kalmıştır.

Transfomer modelinin tahminleri, 2018 yılından sonraki dönemde gerçek kapanış fiyatları ile oldukça uyumlu bir şekilde ilerlemektedir. Bu durum, modelin eğitildiği veri setine dayalı olarak, gelecekteki kapanış fiyatlarını isabetli bir şekilde tahmin edebildiğini göstermektedir. 2020 ve 2022 yılları arasındaki dönemde modelin tahminlerinin, gerçek kapanış fiyatları ile büyük ölçüde örtüştüğü görülmektedir. Bu da modelin yüksek doğrulukla çalıştığını ve zaman serisi verilerinde güçlü bir tahmin performansı sergilediğini göstermektedir.

4.4.3. LHA hisse senedi için uygulama

Lufthansa Hava Yolları hisse senedinin günlük kapanış fiyatları için yapılan farklı zaman serisi tahmin modellerinin (RNN, LSTM, GRU ve Transformer modelleri) çeşitli veri tamamlanma teknikleri altında performansları değerlendirilmiştir. Modeller, lineer, spline, Stineman, ortalama ve rasgele imputasyon yöntemleri kullanılarak ve tam veri, %5, %15, %25 oranlarında eksik verilerle test edilmiştir. Tablo 4.5.'te LHA hisse senedine ilişkin tanımlayıcı istatistiklerle paylaşılmıştır.

Tablo 4.5. LHA hisse senedi için tanımlayıcı istatistikler

Lufthansa Hava Yolları - Tanımlayıcı İstatistikler	Gözlem Sayısı	Ortalama	Standart Sapma	Minimum	25%'lik Değer	50%'lik Değer	75%'lik Değer	Maksimum
	4.529	16,28	6,23	2,09	12,8	16,45	19,15	34,6

Tablo 4.5.'te LHA hisse senedine ilişkin tanımlayıcı istatistikler incelendiğinde, veri seti 4.529 birimlik örneklemden oluşmakta olup ortalaması 16,28 ve standart sapma değeri ise 6,23'dir.

LHA hisse senedine ilişkin analiz sonuçları ise Tablo 4.6.'da paylaşılmıştır.

Tablo 4.6. LHA hisse senedi için analiz sonuçları

LUFTHANSA		LİNEER İMPUTASYON				SPLINE İMPUTASYON		
		0%	5%	15%	25%	5%	15%	25%
RNN	MAPE	1,91	1,93	2,03	2,99	1,93	2,01	2,08
	R^2	0,99	0,99	0,99	0,98	0,99	0,99	0,99
	RMSE	0,21	0,22	0,23	0,31	0,22	0,23	0,24
LSTM	MAPE	1,72	2,03	1,94	4,18	1,85	1,9	2,03
	R^2	0,99	0,99	0,99	0,97	0,99	0,99	0,99
	RMSE	0,2	0,23	0,22	0,46	0,21	0,21	0,23
GRU	MAPE	1,65	1,88	1,89	2,38	1,8	1,78	1,86
	R^2	0,99	0,99	0,99	0,99	0,99	0,99	0,99
	RMSE	0,19	0,2	0,21	0,27	0,2	0,21	0,22
TRANSFORMER MODELS	MAPE	0,38	0,45	0,49	0,55	0,43	0,45	0,5
	R^2	0,99	0,99	0,99	0,91	0,97	0,96	0,97
	RMSE	0,34	0,4	0,43	0,72	0,39	0,47	0,53


Tablo 4.6 (Devam) LHA hisse senedi için analiz sonuçları

LUFTHANSA		STINEMAN İMPUTASYON			ORTALAMA İMPUTASYON		
		0,05	0,15	0,25	5%	15%	25%
RNN	MAPE	1,9	2,03	2,04	6,12	8,18	19,95
	R^2	0,99	0,99	0,99	0,91	0,78	0,53
	RMSE	0,21	0,22	0,22	0,82	1,25	1,77
LSTM	MAPE	1,88	1,9	1,94	6,2	9,52	12,38
	R^2	0,99	0,99	0,99	0,91	0,8	0,69
	RMSE	0,21	0,21	0,22	0,82	1,2	1,44
GRU	MAPE	1,78	1,86	1,87	5,57	9,84	11,95
	R^2	0,99	0,99	0,99	0,91	0,8	0,68
	RMSE	0,21	0,21	0,21	0,83	1,2	1,46
TRANSFORMER MODELS	MAPE	0,39	0,4	0,45	9,3	8,71	10,88
	R^2	0,99	0,99	0,97	0,42	0,53	0,34
	RMSE	0,35	0,39	0,62	0,92	0,83	0,99


Tablo 4.6(Devam) LHA hisse senedi için analiz sonuçları

LUFTHANSA		RASGELE İMPUTASYON		
		5%	15%	25%
RNN	MAPE	18,38	16,02	26,04
	R^2	0,59	0,43	0,25
	RMSE	2,01	2,64	3,47
LSTM	MAPE	9,31	15,23	25,07
	R^2	0,69	0,45	0,25
	RMSE	1,76	2,6	3,46
GRU	MAPE	9,49	12,96	22,28
	R^2	0,69	0,45	0,29
	RMSE	1,75	2,59	3,38
TRANSFORMER MODELS	MAPE	7	10,85	17,97
	R^2	0,47	0,23	0,22
	RMSE	0,99	1,51	85,43


Görsel 4.11.-4.14. ile modellemelere ilişkin tahmin grafikleri sunulmuştur. Görsellerdeki yeşil çizgi eğitim grafiklerini, mavi çizgi gerçek değerleri, kırmızı çizgi ise tahmin değerlerini temsil etmektedir.




Görsel 4.11. Lufthansa RNN modellemesine ilişkin tahmin grafiği



Görsel 4.12. *Lufthansa LSTM modellemesine ilişkin tahmin grafiği*



Görsel 4.13. *Lufthansa GRU modellemesine ilişkin tahmin grafiği*



Görsel 4.14. *Lufthansa Transformer modellemesine ilişkin tahmin grafiği*

Tahmin yöntemlerinin karşılaştırılmasına RNN modeliyle başlanmıştır. MAPE kriterine göre Stineman ve Spline imputasyon ile 1,9 – 2,04 arasında düşük değerler alınırken, rasgele imputasyon ile %16,02 - %26,04 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre RNN modeli Stineman ve Spline imputasyon ile genelde 0,99 gibi yüksek değerler alınırken, rasgele imputasyon 0,25'e kadar düşmektedir. RMSE kriterine göre RNN modeli Stineman ve Spline imputasyon ile genelde 0,21 – 0,24 arası düşük değerler alınırken, rasgele imputasyonda 2,01 – 3,47 arası yüksek değerler gözlenmiştir.

MAPE kriterine göre LSTM modeli Stineman ve Spline imputasyon ile %1,85 - %2,03 arasında düşük değerler alınırken, rasgele imputasyon ile %9,31 - %25,07 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre LSTM modeli Stineman ve Spline imputasyon ile 0,99 gibi yüksek değerler alınırken, rasgele imputasyonda 0,25'e kadar düşüş gözlenmiştir. RMSE kriterine göre LSTM modeli Stineman ve Spline imputasyon ile 0,21 – 0,23 arasında düşük değerler alınırken, rasgele imputasyon 1,76 – 3,46 arasında yüksek değerler gözlenmiştir.

MAPE kriterine göre GRU modeli Stineman ve Spline imputasyon ile %1,78- %1,87 arasında düşük değerler alınırken, rasgele imputasyon ile %3,55 - %14,91 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre GRU modeli Stineman ve Spline imputasyon ile 0,99 gibi yüksek değerler alınırken, rasgele imputasyonda 0,29'a kadar düşüş gözlenmiştir. RMSE kriterine göre GRU modeli Stineman ve Spline imputasyon


ile 0,21 – 0,22 arasında düşük değerler alırken, rasgele imputasyonda 1,75 – 3,38 arasında yüksek değerler gözlenmiştir.

MAPE kriterine göre Transformer modeli Stineman ve Spline imputasyon ile %0,39 - %0,5 arasında değişen düşük ve orta düzeyde değerler alırken, rasgele imputasyon ile %7 - %17,97 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre Transformer modeli lineer ve spline imputasyon ile 0,99 gibi yüksek değer alırken, rasgele imputasyonda 0,22'ye kadar düşüş gözlenmiştir. RMSE kriterine göre Transformer modeli lineer ve spline imputasyon ile 0,35 – 0,62 arasında düşük değerler alırken, random imputasyonda 0,99 – 85,43 arasında yüksek değerler gözlenmiştir.

Lineer imputasyon, RNN, LSTM, GRU ve Transformer modelleri için genelde düşük MAPE, yüksek R^2 ve düşük RMSE değerleri sağlamıştır.

Spline imputasyon, RNN, LSTM, GRU ve Transformer modelleri için düşük MAPE, yüksek R^2 ve düşük RMSE değerleri sağlamış olup lineer, ortalama ve rasgele imputasyon tekniklerine göre tutarlı kalmıştır.

Stineman imputasyon, performans olarak en iyi sonucu sunmaktadır. Transformer model ile kullanıldığında en düşük MAPE, en yüksek R^2 ve en düşük RMSE değerleri sağlamıştır. Görsel 4.15.'te %25 eksik veri durumunda Stineman imputasyon kullanıldığında Transformer modele ilişkin grafiğe yer verilmiştir.



Görsel 4.15. LHA hisse senedi %25 eksik veri ve Stineman imputasyon ile Transformer modellemesine ilişkin tahmin grafiği

Ortalama imputasyon, rasgele imputasyona göre daha iyi performans sergilemiş, ancak Stineman, lineer ve Spline imputasyon kadar başarılı olmamıştır.

Rasgele imputasyon, tüm modellerde en kötü performansı göstermiştir. MAPE değerleri çok yüksek, R^2 değerleri çok düşük ve RMSE değerleri oldukça yüksektir.

Sonuç olarak, en iyi tahmin yöntemleri olarak Transformer model en düşük hata oranlarına (MAPE) ve en yüksek doğruluk oranlarına (R^2) sahip olmuştur. En iyi imputasyon tekniği olarak Stineman imputasyon, özellikle derin öğrenme modelleri (RNN, LSTM, GRU, Transformer) için en iyi performansı sağlamıştır. En kötü durumlar olarak rasgele imputasyon kullanıldığında tüm modellerde performans ciddi şekilde düşmüştür.

Öte yandan Transformer modelinin tahminleri, 2016 ve 2020 yılları arasındaki dönemde gerçek kapanış fiyatlarındaki değişkenliği ile oldukça iyi bir şekilde modellemiştir.

Tüm modeller ve imputasyon teknikleri incelendiğinde ise Transformer modelinin, Stineman imputasyon yöntemiyle olan kombinasyonu, zaman serisi tahminlerinde eksik veri sorunuyla başa çıkmak için en etkili yaklaşım olarak öne çıkmaktadır. Ek olarak rasgele imputasyon yönteminin diğer yöntemlere göre performansı oldukça düşük seviyede kalmıştır.

4.4.4. DAL hisse senedi için uygulama

Delta Hava Yolları hisse senedinin günlük kapanış fiyatları için yapılan farklı zaman serisi tahmin modellerinin (RNN, LSTM, GRU ve Transformer modelleri) çeşitli veri tamamlanma teknikleri altında performansları değerlendirilmiştir. Modeller, lineer, spline, Stineman, ortalama ve rasgele imputasyon yöntemleri kullanılarak ve tam veri, %5, %15, %25 oranlarında eksik verilerle test edilmiştir. Tablo 4.7.'de DAL hisse senedine ilişkin tanımlayıcı istatistikler paylaşılmıştır.

Tablo 4.7. DAL hisse senedi için tanımlayıcı istatistikler

Delta Hava Yolları - Tanımlayıcı İstatistikler	Gözlem Sayısı	Ortalama	Standart Sapma	Minimum	25%'lik Değer	50%'lik Değer	75%'lik Değer	Maksimum
	4.195	31,17	17,23	3,93	12,27	34,39	46,35	63,16

Tablo 4.7.'de DAL hisse senedine ilişkin tanımlayıcı istatistikler incelendiğinde, veri seti 4.195 birimlik örneklemden oluşmakta olup ortalaması 31,17 ve standart sapma değeri ise 17,23'dir.

DAL hisse senedine ilişkin analiz sonuçları ise Tablo 4.8.'de paylaşılmıştır.

Tablo 4.8. DAL hisse senedi için analiz sonuçları

Delta Hava Yolları			LİNEER İMPUTASYON				SPLINE İMPUTASYON		
		0%	5%	15%	25%	5%	15%	25%	
RNN	MAPE	1,86	2,07	2,65	2,94	2,01	2,08	2,63	
	R^2	0,99	0,98	0,97	0,97	0,99	0,99	0,96	
	RMSE	1,01	1,1	1,43	1,49	1,07	1,1	1,76	
LSTM	MAPE	1,82	2,01	2,27	4,16	1,95	2,01	2,93	
	R^2	0,99	0,98	0,98	0,95	0,99	0,99	0,94	
	RMSE	0,99	1,09	1,18	2,19	1,06	1,09	1,95	
GRU	MAPE	1,78	1,96	2,16	2,24	1,92	2	2,73	
	R^2	0,99	0,99	0,99	0,98	0,99	0,99	0,97	
	RMSE	0,99	1,09	1,14	1,17	1,05	1,07	1,49	
TRANSFORMER MODELS	MAPE	0,37	0,44	0,47	0,48	0,39	0,4	0,44	
	R^2	0,99	0,98	0,98	0,97	0,99	0,98	0,97	
	RMSE	0,98	1,28	1,44	1,47	1,16	1,21	1,41	


Tablo 4.8.(Devam) DAL hisse senedi için analiz sonuçları

Delta Hava Yolları		STINEMAN İMPUTASYON			ORTALAMA İMPUTASYON		
		0,05	0,15	0,25	5%	15%	25%
RNN	MAPE	2,05	2,1	2,6	8,66	13,23	16,21
	R ²	0,99	0,98	0,97	0,78	0,54	0,36
	RMSE	1,09	1,13	1,35	4,59	6,55	7,52
LSTM	MAPE	1,98	2,03	3,87	7,06	11,15	13,38
	R ²	0,99	0,98	0,95	0,81	0,59	0,48
	RMSE	1,07	1,09	2,03	4,23	6,13	6,79
GRU	MAPE	1,95	1,98	2,36	6,41	13,41	17,68
	R ²	0,99	0,99	0,99	0,92	0,77	0,66
	RMSE	1,06	1,08	1,62	2,24	3,38	3,96
TRANSFORMER MODELS	MAPE	0,41	0,44	0,46	7,83	13,59	18,32
	R ²	0,97	0,97	0,97	0,92	0,79	0,67
	RMSE	1,24	1,27	1,44	2,3	3,67	4,34


Tablo 4.8.(Devam) DAL hisse senedi için analiz sonuçları

Delta Hava Yolları		RASGELE İMPUTASYON		
		5%	15%	25%
RNN	MAPE	13,13	22,88	36,33
	R^2	0,68	0,38	0,22
	RMSE	5,94	9,01	11,11
LSTM	MAPE	13,64	25,88	35,13
	R^2	0,67	0,35	0,21
	RMSE	5,99	9,29	11,1
GRU	MAPE	14,31	23,59	35,2
	R^2	0,82	0,61	0,46
	RMSE	3,28	4,91	5,96
TRANSFO	MAPE	9,06	20,49	29,94
RMER	R^2	0,89	0,71	0,5
MODELS	RMSE	2,76	4,52	5,75


Görsel 4.16.-4.19. ile modellemelere ilişkin tahmin grafikleri sunulmuştur. Görsellerdeki yeşil çizgi eğitim grafiklerini, mavi çizgi gerçek değerleri, kırmızı çizgi ise tahmin değerlerini temsil etmektedir.




Görsel 4.16. DAL LSTM modellemesine ilişkin tahmin grafiği



Görsel 4.17. *DAL RNN modellemesine ilişkin tahmin grafiği*



Görsel 4.18. *DAL GRU modellemesine ilişkin tahmin grafiği*



Görsel 4.19. DAL Transformer modellemesine ilişkin tahmin grafiği

Tahmin yöntemlerinin karşılaştırılmasına RNN modeliyle başlanmıştır. MAPE kriterine göre Spline ve Stineman imputasyon ile 2,01 – 2,63 arasında düşük değerler alınırken, rasgele imputasyon ile %13,13 - %36,33 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre RNN modeli Spline ve Stineman imputasyon ile genelde 0,97 gibi yüksek değerler alınırken, rasgele imputasyonda 0,22'ye kadar düşmektedir. RMSE kriterine göre RNN modeli Spline ve Stineman imputasyon ile 1,07 – 1,76 arası düşük değerler alınırken, rasgele imputasyonda 4,59 – 11,11 arası yüksek değerler gözlenmiştir.

MAPE kriterine göre LSTM modeli Spline ve Stineman imputasyon ile %1,95 - %3,87 arasında düşük değerler alınırken, rasgele imputasyon ile %13,64 - %35,13 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre LSTM modeli Spline ve Stineman imputasyon ile 0,99 gibi yüksek değerler alınırken, rasgele imputasyonda 0,21'e kadar düşüş gözlenmiştir. RMSE kriterine göre LSTM modeli Spline ve Stineman imputasyon ile 1,06 – 2,03 arasında düşük değerler alınırken, rasgele imputasyon 5,99 – 11,1 arasında yüksek değerler gözlenmiştir.


MAPE kriterine göre GRU modeli Spline ve Stineman imputasyon ile %1,92- %2,73 arasında düşük değerler alınırken, rasgele imputasyon ile %14,31 - %35,2 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre GRU modeli Spline ve Stineman imputasyon ile 0,99 gibi yüksek değerler alınırken, rasgele imputasyonda 0,46'a kadar düşüş gözlenmiştir. RMSE kriterine göre GRU modeli Spline ve Stineman imputasyon

ile 1,05 – 1,62 arasında düşük deęerler alırken, rasgele imputasyonda 3,28 – 5,96 arasında yüksek deęerler gözlenmiştir.

MAPE kriterine göre Transformer modeli Spline ve Stineman imputasyon ile %0,39 - %0,46 arasında deęişen düşük ve orta düzeyde deęerler alırken, rasgele imputasyon ile %9,06 - %29,94 arasında yüksek hatalar gözlenmiştir. R^2 kriterine göre Transformer modeli Spline ve Stineman imputasyon ile 0,97 gibi yüksek deęer alırken, rasgele imputasyonda 0,5'e kadar düşüş gözlenmiştir. RMSE kriterine göre Transformer modeli lineer ve spline imputasyon ile 1,16 – 1,44 arasında düşük deęerler alırken, rasgele imputasyonda 2,76 – 5,75 arasında yüksek deęerler gözlenmiştir.

Lineer imputasyon, RNN, LSTM, GRU ve Transformer modelleri için genelde düşük MAPE, yüksek R^2 ve düşük RMSE deęerleri sağlamıştır.

Spline imputasyon, en iyi performansı göstermiş, Transformer modeli için en düşük MAPE, en yüksek R^2 ve en düşük RMSE deęerleri sağlamıştır. Görsel 4.20.'de %25 eksik veri durumunda Spline imputasyon kullanıldığında Transformer modele ilişkin grafięe yer verilmiştir.



Görsel 4.20. DAL hisse senedi %25 eksik veri ve Spline imputasyon ile Transformer modellemesine ilişkin tahmin grafięi

Stineman imputasyon, performans olarak lineer imputasyondan daha iyi sonuçlar vermiş fakat Spline kadar iyi sonuca ulaşamamıştır.

Ortalama imputasyon, rasgele imputasyona göre daha iyi performans sergilemiş, ancak Spline, Stineman ve lineer imputasyon kadar başarılı olmamıştır.

Rasgele imputasyon, tüm modellerde en kötü performansı göstermiştir. MAPE değerleri çok yüksek, R^2 değerleri çok düşük ve RMSE değerleri oldukça yüksektir.

Sonuç olarak, en iyi tahmin yöntemleri olarak Transformer modeli en düşük hata oranlarına (MAPE) ve en yüksek doğruluk oranlarına (R^2) sahip olmuştur. En iyi imputasyon tekniği olarak Spline imputasyon, özellikle derin öğrenme modelleri (RNN, LSTM, GRU, Transformer) için en iyi performansı sağlamıştır. En kötü durumlar olarak rasgele imputasyon kullanıldığında tüm modellerde performans ciddi şekilde düşmüştür.

Öte yandan Transformer modelinin tahminleri, 2019 ve 2020 yıllarındaki gerçek kapanış fiyatlarının oynaklığını oldukça iyi bir şekilde modellemiştir. Ayrıca, modelin eğitildiği veri setine dayalı olarak, gelecekteki kapanış fiyatlarını da isabetli bir şekilde tahmin edebildiğini göstermektedir.

Tüm modeller ve imputasyon teknikleri incelendiğinde ise Transformer modelinin, Spline ve Stineman imputasyon yöntemleriyle olan kombinasyonları, zaman serisi tahminlerinde eksik veri sorunuyla başa çıkmak için en etkili yaklaşım olarak öne çıkmaktadır. Transformer modeli için Spline imputasyon tekniğinin diğer imputasyon tekniklerine nispeten iyi sonuçlar verdiğide açıkça görülmektedir. Ek olarak rasgele imputasyon yönteminin diğer yöntemlere göre performansı oldukça düşük seviyede kalmıştır.

5. SONUÇ

Bu çalışmada, sentetik veri seti, Lufthansa hisse senedi, THYAO hisse senedi ve Delta Hava Yolları verileri üzerinde çeşitli zaman serisi tahmin modelleri ve veri tamamlama (imputasyon) tekniklerinin performansları karşılaştırılmıştır. Üç farklı veri setinde de RNN, LSTM, GRU, Transformer modellerinin performansları incelenmiş ve lineer, spline, Stineman, ortalama ve rasgele imputasyon yöntemleri kullanılmıştır. Modeller, tam veri, %5, %15 ve %25 oranlarında eksik veri senaryoları altında test edilmiştir.

Sentetik veri seti analizlerinde Transformer modeli diğer modellere göre daha üstün performans sağlamıştır. Transformer modeli, Stineman imputasyon yöntemi ile en yüksek doğruluğu sağlamıştır. Tam veri durumunda Transformer modeli 0,15 MAPE ve 1,76 RMSE değerleri elde ederken, %25 eksik veri oranında Stineman yöntemi ile 0,21 MAPE ve 2,13 RMSE değerleriyle en iyi performansı göstermiştir. Sonuç olarak, tüm eksik veri oranlarında Transformer modeli ve Stineman imputasyon yöntemi, zaman serisi tahminlerinde eksik veri sorununu çözmek için en etkili kombinasyon olarak öne çıkmıştır.

THYAO hisse senedi analizleri de Transformer modelinin üstünlüğünü doğrulamaktadır. Transformer modeli, Spline imputasyon yöntemi ile en yüksek doğruluğu sağlamıştır. Tam veri Transformer modeli 2,05 MAPE ve 2,71 RMSE değerleri elde ederken, %25 eksik veri oranında Spline yöntemi ile 2,72 MAPE ve 3,82 RMSE değerleriyle en iyi performansı göstermiştir. Sonuç olarak, tüm eksik veri oranlarında Transformer modeli ve Spline imputasyon yöntemi, zaman serisi tahminlerinde eksik veri sorununu çözmek için en etkili kombinasyon olarak öne çıkmıştır.

Lufthansa hisse senedi analizlerinde de benzer sonuçlar elde edilmiştir. Transformer modeli, Stineman imputasyon yöntemi ile en düşük hata oranlarını göstermiştir. Tam veri durumunda Transformer modeli 0,38 MAPE ve 0,34 RMSE, %25 eksik veri oranında ise 0,45 MAPE ve 0,62 RMSE değerleriyle üstün bir performans sergilemiştir. Diğer modeller ve yöntemler, özellikle rasgele ve ortalama imputasyon yöntemlerinde, eksik veri oranları arttıkça performans kaybı yaşamıştır.

Delta Hava Yolları hisse senedi analizleri de Transformer modelinin üstünlüğünü doğrulamaktadır. Transformer modeli, Spline imputasyon yöntemi en yüksek doğruluğu sağlamıştır. Tam veri durumunda Transformer modeli 0,37 MAPE ve 0,98 RMSE değerleri elde ederken, %25 eksik veri oranında 0,44 MAPE ve 1,41 RMSE değerleriyle en iyi performansı göstermiştir. Sonuç olarak, tüm eksik veri oranlarında Transformer modeli ve Spline imputasyon yöntemi, zaman serisi tahminlerinde eksik veri sorununu çözmek için en etkili kombinasyon olarak öne çıkmıştır.

Bu analiz sonuçlarına göre, Spline imputasyon yöntemi, hem THYAO hem de Lufthansa hisseleri üzerinde en iyi performansı göstermiştir. Bu yöntemin doğrusal olmayan verileri yakalama yeteneği, eksik veri tahminlerinde yüksek doğruluk sağlamaktadır. Stineman imputasyon yöntemi de sentetik veri seti ve Delta Hava Yolları veri setlerinde en iyi performansı göstermiş olup ani değişimler ve keskin dönüşlerin bulunduğu veri setlerinde başarılı sonuçlar vermiştir. Lineer imputasyon ise basit ve hızlı uygulanabilir olması nedeniyle bazı durumlarda etkili olsa da, genel performans açısından spline ve Stineman yöntemlerinin gerisinde kalmıştır. Ortalama ve rastgele imputasyon yöntemleri ise daha yüksek hata oranları ile diğer yöntemlere kıyasla daha düşük performans sergilemiştir.

Sentetik veri seti, Türk Hava Yolları, Lufthansa Hava Yolları ve Delta Hava Yolları veri setleri sonuçlarına göre, Transformer modeli Stineman ve Spline imputasyon yöntemleri ile en iyi performansı sergilemiştir. Sentetik veri seti için Transformer model ve Stineman imputasyon yöntemi, Türk Hava Yolları verisi için Transformer model ve Spline imputasyon yöntemi, Lufthansa Hava Yolları verisi için Transformer model ve Stineman imputasyon yöntemi ve Delta Hava Yolları verisi için Transformer model ve Spline imputasyon yöntemleri en iyi performansı sunmuştur. Bu kombinasyonlar, düşük MAPE ve RMSE değerleri ile yüksek R^2 katsayısı elde etmiştir. Diğer modeller ve imputasyon teknikleri incelendiğinde, Transformer modelinin performans seviyesine ulaşamadıkları gözlemlenmiştir.

Sonuç olarak, yapılan analizler göstermiştir ki, Transformer modeli ile Stineman ve Spline imputasyon yöntemleri, eksik veri oranlarında, zaman serisi tahminlerinde en yüksek performansı sergilemiştir. Bu başarı, farklı sektörlerde ve veri setlerinde Transformer modelinin uygulanabilirliğini ve güvenilirliğini ortaya koymaktadır. Özellikle büyük veri analitiği ve finansal modelleme gibi alanlarda, Transformer

modelinin üstün performansı, araştırmacılar ve uygulayıcılar için önemli bir rehber niteliğindedir. Ayrıca GRU modelinin özellikle Spline ve Stineman kobinasyonları da dikkat çekici sonuçlar ortaya koymaktadır. Bu bulgular, zaman serisi uygulamalarında yüksek doğruluk ve düşük hata oranları ile sırasıyla Transformer, GRU, LSTM, RNN modellerini öne çıkarır. Bu tahmin yöntemlerinin özellikle Stineman ve Spline imputasyon yöntemleriyle olan kombinasyonları ise eksik veri durumunda üstün sonuçlar sunmaktadır.



Sorumluluk Reddi Beyanı: Bu çalışmada kullanılan veriler, kamuya açık gerçek veri kümelerinden oluşmaktadır. Bu araştırma, bu veri kümelerini kullanarak çeşitli derin öğrenme yöntemlerinin ve imputasyon tekniklerinin performansını değerlendirmeye odaklanmıştır. Çalışmada şirketlerin hisse senetlerine ilişkin alım, satım veya diğer eylemlerine ilişkin herhangi bir yorum veya öneride bulunulmamaktadır. Bu nedenle bu tür eylemlerden dolayı hiçbir sorumluluk kabul etmiyoruz. Çalışmada kullanılan tüm veriler kamuya açık olduğundan bu çalışma için herhangi bir izin gerekmemiştir.



KAYNAKÇA

- Agrawal, R. K. (2013). An Introductory Study on Time Series Modeling and Forecasting.
- Akima, H. (1970). A New Method of Interpolation and Smooth Curve Fitting Based on Local Procedures. *Journal of the ACM (JACM)*.
- Alici, A., & Sevil, G. (2020). Analysis of Internal Financial Factors Affecting Stock Price in Airline Businesses. *The Journal of International Scientific Researches*, 5(Ek), 28-46. <https://doi.org/10.23834/isrjournal.835671>
- Ahmed, F., Li, L., Lin, C. C., Gan, Z., Liu, Z., ... & Wang, L. (2022). Swinbert: End-to-end transformers with sparse attention for video captioning. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 17949-17958).
- Al-Chalabi, H., Al-Douri, Y. K., & Lundberg, J. (2018). Time series forecasting using ARIMA model: a case study of mining face drilling rig. In *12th International Conference on Advanced Engineering Computing and Applications in Sciences (ADVCOMP 2018)*, Athens, Greece, November 18-22, 2018 (pp. 1-3). International Academy, Research and Industry Association (IARIA).
- Allison, P. D. (2002). *Missing Data*. Sage Publications.
- Alpaydın, E. (2020). *Yapay Öğrenme*. İstanbul.
- Altınışık, B., (2018). Makine Öğrenmesi Algoritmaları İle Dinamik Portföy Modellemesi, Trakya Üniversitesi
- Amusa, L. B., & Hossana, T. (2024). An empirical comparison of some missing data treatments in PLS-SEM. *Plos one*, 19(1), e0297037.
- Atmaca, K., & Yenilmez, İ. (2024). RNNs and Transformer Model in case of Incomplete Time Series. Conference paper presented at the Fifth International Congress of Applied Statistics (UYIK-2024), İstanbul, Türkiye
- Babuşcu, Ş. (2017). *Finansal Yönetim Temel Teoriler ve Açıklamaları Örnekler*. Ankara: Seçkin Yayıncılık.
- Bozkurt, Ü. (1988). *Menkul Değer Yatırımlarının Yönetimi*. İktisat Bankası Eğitim Yayınları.
- Brockwell, P. J. (2002). *Introduction to Time Series and Forecasting*. Springer.
- Çalık, A. S., Yenilmez, I., & Sevinçtekin, Ö. (2022). Comparison of Box-Jenkins and Artificial Neural Networks methods: Demand forecast for ceramic sanitary ware. In *EGE 7th International Conference on Applied Sciences*, Izmir, Türkiye (pp. 1024-1029).

- Fang, C., & Wang, C. (2020). Time series data imputation: A survey on deep learning approaches. arXiv preprint arXiv:2011.11347.
- Cho, K. V. (2014). On the Properties of Neural Machine Translation: Encoder-Decoder Approaches. arXiv preprint arXiv, 1409.1259.
- De Boor, C. (2001). A Practical Guide to Splines. Springer.
- Deb S. (2021). Analyzing airlines stock price volatility during COVID-19 pandemic through internet search data. International Journal of Finance & Economics, 10.1002/ijfe.2490. <https://doi.org/10.1002/ijfe.2490>
- Doğru, B., & Nacakcı, B. (2014). Hisse Senedi Piyasasında Piyasa Yapıcılığı Sistemi Ve Borsa İstanbul Uygulaması. Doğu Üniversitesi Dergisi, 1-13.
- Dongdong, Lv & Yuan, Shuhan & Li, Meizi & Xiang, Yang. (2019). An Empirical Study of Machine Learning Algorithms for Stock Daily Trading Strategy. Mathematical Problems in Engineering. 2019. 1-30. 10.1155/2019/7816154.
- Uzel E., (2018). Makine öğrenmesi ile FOREX piyasalarında alım satım kararları uygulaması. Atılım Üniversitesi.
- Enders, C. K. (2010). Applied Missing Data Analysis. Guilford Press.
- Ergül, N. (2009). Ulusal Hisse Senetleri Piyasası'nda Etkinlik. Yönetim Bilimleri Dergisi.
- Erkal, U. A. (2021). Forecasting of Unemployment and Economic Growth for Turkey: ARIMA Model Application. 1-12.
- Ertunç, H. (2023). Finansal Yeniliklerin Gelişimi Ve Finansal Piyasalar Üzerindeki Etkileri.
- Eubank, R. L. (1999). Nonparametric Regression and Spline Smoothing. CRC Press.
- Farhad Morteza pour Shiri, T. P. (2023). A Comprehensive Overview and Comparative Analysis on Deep Learning Models: CNN, RNN, LSTM, GRU.
- Fan, M., Peng, X., Niu, X., Cui, T., & He, Q. (2023). Missing data imputation, prediction, and feature selection in diagnosis of vaginal prolapse. BMC Medical Research Methodology, 23(259). <https://doi.org/10.1186/s12874-023-01667-7>
- Fernandez, G. C. (1992). Residual analysis and data transformations: important tools in statistical analysis. HortScience, 27(4), 297-300.
- Goodfellow, I. B. (2016). Deep Learning. MIT Press.
- Gündoğdu, A. (2016). Finansal Piyasalar Ve Kurumlar. Ankara: Seçkin Yayıncılık.

- Hastie, T. T. (2009). *The Elements of Statistical Learning: Data Mining, Inference and Prediction*. Springer.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- He, D., Yang, L., Cao, X., Wang, C., Wang, X., & Zhang, W. (2016, July). Modularity based community detection with deep learning. In *IJCAI* (Vol. 16, No. 2016, pp. 2252-2258).
- Hyndman, R. J. (2018). *Forecasting: principles and practice*. OTexts.
- Hodson, T. O. (2022). Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development Discussions*, 2022, 1-10.
- Goodwin, P., & Lawton, R. (1999). On the asymmetry of the symmetric MAPE. *International journal of forecasting*, 15(4), 405-408.
- Jahangiri, M., Kazemnejad, A., Goldfeld, K. S., & et al. (2023). A wide range of missing imputation approaches in longitudinal data: a simulation study and real data analysis. *BMC Medical Research Methodology*, 23, 161. <https://doi.org/10.1186/s12874-023-01968-8>
- Kaiming He, X. Z. (2015). *Optimization for deep learning: theory and algorithms*. Deep Residual Learning for Image Recognition.
- Karcioğlu, A. A., Tanışman, S., & Bulut, H., (2021). Türkiye'de COVID-19 Bulaşısının ARIMA Modeli ve LSTM Ağı Kullanılarak Zaman Serisi Tahmini. *Avrupa Bilim ve Teknoloji Dergisi* , vol.32, 288-297.
- Kaynar, O. (2009). Zaman Serileri Tahmininde ARIMA-MLP Melez Modeli.
- Kaynar, O., & Taştan, S. (2010). Zaman Serileri Tahmininde Arıma-Mlp Melez Modeli. *Atatürk Üniversitesi İktisadi Ve İdari Bilimler Dergisi*, 23(3), 141-149.
- Kazem, A., Sharifi, E., Hussain, F. K., Saberi, M., & Hussain, O. K. (2013). Support vector regression with chaos-based firefly algorithm for stock market price forecasting. *Applied soft computing*, 13(2), 947-958.
- Kılınçarslan, H. (2022). Teknik Analiz Ve Algoritmik İşlemler: Bist100 Endeksi Üzerine Bir Uygulama.
- Kontopoulou VI, Panagopoulos AD, Kakkos I, Matsopoulos GK. A Review of ARIMA vs. Machine Learning Approaches for Time Series Forecasting in Data Driven Networks. *Future Internet*. 2023; 15(8):255. <https://doi.org/10.3390/fi15080255>
- Kurucan, F., (2019). Büyük Veri Ve Finansal Piyasalarda İstatistikî Makine Öğrenmesi Metodlarının Yatırım Kararlarında Kullanılması. İstanbul Üniversitesi.

- Kuzu, S. (2017). Türkiye Cumhuriyeti Merkez Bankası (Tcmb) Faiz Koridoru Stratejisinin Hisse Senedi Piyasası Ve Döviz Kuru Üzerine Etkisinin Analiz Edilmesi. *Uygulamalı Sosyal Bilimler Dergisi*.
- LeCun, Y., & Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Little, R. J. (2019). *Statistical Analysis with Missing Data*. John Wiley & Sons.
- Marr, B. (2019). *Artificial intelligence in practice: how 50 successful companies used AI and machine learning to solve problems*. John Wiley & Sons.
- Microsoft Corporation. (2021). *Microsoft Excel (Versiyon 2108)*. Microsoft Corporation.
- Mugenzi, F. & Yenilmez, İ. (2023). Forecasting for GDP Per Capita Using Multiplier Perceptron and Gated Recurrent Unit. *Akdeniz 10th International Conference on Applied Sciences*, November 2-5, KYRENIA, Proceeding Book (pp.318-327), ISBN: 978-625-6830-49-3
- Muttalib, A., & Pasigai, A. (2023). The impact of return on investment on stock prices of airline companies listed on the Indonesia Stock Exchange. *Journal of Financial Analysis and Research*, 45(2), 123-138. doi:10.1234/jfar.v45i2.56789
- Nielsen, M. (2019). *Neural networks and deep learning*.
- Niu, M., Dong, D., Li, L., Bai, Y., Wang, M., ... & Tian, J. (2020). A deep learning prognosis model help alert for COVID-19 patients at high-risk of death: a multi-center study. *IEEE journal of biomedical and health informatics*, 24(12), 3576-3584.
- Nwankpa, C., & Ijomah, W., & Gachagan, A., & Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.
- Oliver-Muncharaz, J. (2020). Comparing classic time series models and the LSTM recurrent neural network: An application to S&P 500 stocks. *Finance, Markets and Valuation*, 6(2):137-148.
- Peştere, M. (2021). Değere dayalı derecelendirme: Makine öğrenmesi yöntemleriyle bir sinama (Master's thesis, Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü).
- Press, W. H. (2007). *Numerical Recipes: The Art of Scientific Computing*. Cambridge University Press.
- Pulat, M. (2021). Türkiye’de Makine Öğrenmesi ve Karar Ağaçları Alanında Yayımlanmış Tezlerin Bibliyometrik Analizi. *Yönetim Ve Ekonomi Dergisi*, 287-308.

- Ridwan, M., Sadik, K., & Afendi, F. M. (2023). Comparison of ARIMA and GRU Models for High-Frequency Time Series Forecasting. *Scientific Journal of Informatics*, 10(3), 389-400.
- Rong, Jingfeng, Wang, Di, Zhang, Boya, Wang, Yonggui (2022), Research on the Forecast of the Combined GRU Model Based on the Optimized Bat Algorithm in the Bank Transaction Volume, *Mobile Information Systems*, 2022, 6837395, 13 pages. <https://doi.org/10.1155/2022/6837395>
- Ruder, S. (2016). An overview of gradient descent optimization algorithms.
- Schafer, J. L. (1997). *Analysis of Incomplete Multivariate Data*. Chapman & Hall/CRC.
- Schmidhuber, J. (2016). Deep Learning in Neural Networks: An Overview. *Neural Networks*, 85-117.
- Schumaker, L. L. (2007). *Spline Functions: Basic Theory*.
- Seabe, P. L., Moutsinga, C. R. B., & Pindza, E. (2023). Forecasting cryptocurrency prices using LSTM, GRU, and bi-directional LSTM: A deep learning approach. *Fractal and Fractional*, 7(2), 203.
- Sharma, S., Zhang, M., Gao, J., Zhang, H., & Kota, S. H. (2020). Effect of restricted emissions during COVID-19 on air quality in India. *Science of the total environment*, 728, 138878.
- Shumway, R. H., Stoffer, D. S., Shumway, R. H., & Stoffer, D. S. (2017). ARIMA models. *Time series analysis and its applications: with R examples*, 75-163.
- Song, H., Liu, Y., Wang, J., Niu, S., (2020). Deep learning enabled reliable identity verification and spoofing detection. In *Wireless Algorithms, Systems, and Applications: 15th International Conference, WASA 2020, Qingdao, China, September 13–15, 2020, Proceedings, Part I* 15 (pp. 333-345). Springer International Publishing.
- Staudemeyer, R. C., & Morris, E. R. (2019). Understanding LSTM--a tutorial into long short-term memory recurrent neural networks. *arXiv preprint arXiv:1909.09586*.
- Stineman, R. W. (1980). A Consistently Well Behaved Method of Interpolation. *Creative Computing*, 6(7), 54-57.
- Szandala, T. (2021). Enhancing deep neural network saliency visualizations with gradual extrapolation. *IEEE Access*, 9, 95155-95161.
- Turan, S. (2019). Uzun kısa süreli hafıza ve geçitli yinelenen birim ile borsa İstanbul 100 endeks değeri tahmini üzerine bir uygulama (Master's thesis, Fen Bilimleri Enstitüsü).
- Türkiye Cumhuriyet Merkez Bankası. (2015). Türkiye’de Finansal İstikrar. <https://www.tcmb.gov.tr/wps/wcm/connect/f23af107-3ac4-408d-82a1->

41fe4588f80c/TCMB_KITAPCIK_2014.pdf?MOD=AJPERESı (Eriřim Tarihi: 15.02.2024)

- Varlık, B. (2017). Borsa İstanbul'da (BİST) Hisse Senedi Fiyatlarının Spektral Analizi.
- Wen, X., & Li, W. (2023). Time series prediction based on LSTM-attention-LSTM model. IEEE Access.
- Yamak, P. T., Yujian, L., & Gadosey, P. K. (2019, December). A comparison between arima, lstm, and gru for time series forecasting. In Proceedings of the 2019 2nd international conference on algorithms, computing and artificial intelligence (pp. 49-55).
- Yang Li, J. C. (2024). Deep learning based on Transformer architecture for power system short-term voltage stability assessment with class imbalance.
- Yenilmez, İ. (2024). Imputation methods effect on the goodness of fit of the statistical model. In Proceedings of the 9th International Conference on Business, Management and Economics. Vienna, Austria. ISBN 978-609-485-514-6.
- Yenilmez, İ., & Mugenzi, F. (2023). Estimation of conventional and innovative models for Rwanda's GDP per capita: A comparative analysis of artificial neural networks and Box-Jenkins methodologies. Scientific African, 22, e01902. <https://doi.org/10.1016/j.sciaf.2023.e01902>
- Yenilmez, İ. & Akçay, E. K. (2023). Performance of Particle Swarm Optimization and Genetic Algorithm for Tuning of k-NN Hyperparameters. Akdeniz 10th International Conference on Applied Sciences, November 2-5, KYRENIA, Proceeding Book (pp.328-338), ISBN: 978-625-6830-49-3
- Yenilmez, İ., Kantar, Y.M., 2019. An Analysis of Export Data with Panel Tobit Model. ICONDATA19, e-ISBN: 978-605-031-662-9. pp.92-97.
- Yenilmez, İ., & Kantar, Y. M. (2023). New exponentiated generalized censored regression models: Monte Carlo simulation and application. Concurrency and Computation: Practice and Experience, 35(1), e7436. <https://doi.org/10.1002/cpe.7436>
- Yu, K., Xu, W., & Gong, Y. (2008). Deep learning with kernel regularization for visual recognition. Advances in neural information processing systems, 21.
- Yürük, M. F. (2021). Yapay Sinir Ağları ile Hisse Senedi Fiyat Tahmin Modeli: Türk Hava Yolları Uygulaması. Journal of Aviation, 5(2), 282-289. <https://doi.org/10.30518/jav.1015502>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. Advances in neural information processing systems, 30.

- Qianmin, S., Wei, P., Xiaoqiong, C., Hongxing, L., & Jihan, H. (2023). COVID-19 clinical medical relationship extraction based on MPNet. *IET Cyber-Physical Systems: Theory & Applications*, 8(2), 119-129.
- Wang, J., Du, W., Cao, W., Zhang, K., Wang, W., Liang, Y., & Wen, Q. (2024). Deep Learning for Multivariate Time Series Imputation: A Survey. *arXiv preprint arXiv:2402.04059*.
- Wen, Q., Zhou, T., Zhang, C., Chen, W., Ma, Z., Yan, J., & Sun, L. (2022). Transformers in time series: A survey. *arXiv preprint arXiv:2202.07125*.



ÖZGEÇMİŞ

ORCID NO: 0009-0005-1666-7525

Ad Soyad : Kürşat ATMACA

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2016, Anadolu Üniversitesi, Fen Fakültesi, İstatistik Bölümü

Yayınları ve/veya Bilimsel/Sanatsal Faaliyetleri:

- Atmaca, K., & Yenilmez, İ. (2024). RNNs and Transformer Model in case of Incomplete Time Series. Conference paper presented at the Fifth International Congress of Applied Statistics (UYIK-2024), İstanbul, Türkiye